

**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

Diplomski rad

**ALATI ZA VIZUALIZACIJU PODATAKA I
NJIHOVA PRIMJENA U HRVATSKOJ**

Mentor:

dr. sc. Maja Ćukušić

Student:

Antonia Pivac

Split, kolovoz, 2017.

Sadržaj

1.	Uvod	3
1.1.	Problem istraživanja	3
1.2.	Predmet istraživanja	4
1.3.	Istraživačka pitanja	5
1.4.	Ciljevi istraživanja	6
1.5.	Metode istraživanja.....	7
1.6.	Doprinos istraživanja	7
1.7.	Struktura diplomskog rada.....	8
2.	Poslovna inteligencija	9
2.1.	Poslovna inteligencija i njena primjena u poslovanju	9
2.1.1.	Poslovna inteligencija	9
2.1.2.	Primjena poslovne inteligencije u poslovanju.....	10
2.2.	Trendovi u poslovnoj inteligenciji.....	12
2.3.	Poslovna inteligencija u Hrvatskoj	16
3.	Vizualizacija podataka	18
3.1.	Vizualizacija podataka kao dio poslovne inteligencije.....	18
3.1.1.	Interaktivna sučelja (Dashboards)	21
3.2.	Uloga vizualizacije podataka u poduzeću	21
3.3.	Utjecaj vizualizacije podataka na poslovanje organizacije	24
3.3.1.	Primjer 1. Boeing	25
3.3.2.	Primjer 2. Barclays	26
3.3.3.	Primjer 3. Wells Fargo	27
3.3.4.	Primjer 4. Swedish Medical Center.....	29
3.3.5.	Primjer 5. Seattle Children's hospital	30
3.4.	Vizualizacija podataka u Hrvatskoj	31
4.	Alati za vizualizaciju podataka	33

4.1.	Karakteristike alata za vizualizaciju	35
4.1.1.	Što korisnici očekuju od alata za vizualizaciju?.....	37
4.2.	Najpoznatiji svjetski alati za vizualizaciju podataka	39
4.2.1.	Microsoft	41
4.2.2.	Tableau	43
4.2.3.	Qlik.....	45
4.2.4.	SAP.....	47
4.2.5.	IBM	48
4.2.6.	Oracle	49
4.2.7.	Pentaho	50
4.3.	Usporedba alata za vizualizaciju	51
4.3.1.	AHP metoda	51
4.3.2.	Prednosti i nedostaci alata za vizualizaciju podataka.....	58
4.4.	Hrvatski alati za vizualizaciju.....	70
5.	Primjena alata za vizualizaciju u Hrvatskoj	74
5.1.	Svjetski alati u hrvatskim organizacijama	75
5.2.	Kako primjena alata za vizualizaciju podataka utječe na poslovanje Hrvatskih organizacija	80
5.3.	Najveći problemi hrvatskih organizacija vezani uz alate za vizualizaciju podataka.	84
6.	Zaključak.....	87
	Sažetak	90
	Summary	90
	Literatura	91
	Popis slika	96
	Popis tablica	96
	Popis grafikona.....	96

1. Uvod

1.1. Problem istraživanja

Poslovna inteligencija (eng. *Business intelligence*) kao pojam objedinjuje nekoliko metodologija i softverskih alata, kao što su Skladištenje podataka (eng. *Data Warehousing*), Rudarenje podataka (eng. *Data minig*) te OLAP sustavi. Korištenje poslovne inteligencije u poslovanju omogućava pohranjivanje podataka prikupljenih iz različitih izvora te njihovo korištenje u poslovne svrhe, odnosno obrada podataka kako bi se dobile informacije na temelju kojih se donose poslovne odluke. Primjena poslovne inteligencije u poduzećima u novije vrijeme zauzima sve veći značaj, koristi se kako bi se stvaralo znanje i prikupile informacije o konkurenciji, stanju na tržištu, kupcima, poslovnim partnerima i slično¹. Upravo zbog velike potrebe za podacima i sve učestalijeg korištenja poslovne inteligencije u svakodnevnom poslovanju, dolazi i do potrebe za agilnosti podataka kako bi mogli pratiti sve agilnije poslovanje organizacije. To je razlog zašto većina organizacija nastoji prikupljati vlastite podatke umjesto outsourcing-a istih².

S obzirom da poduzeća danas raspolažu sa velikim količinama podataka postalo je gotovo nemoguće pratiti sve promjene i kvalitetno ih iskoristavati za potrebe poslovanja. Stoga je primjena alata poslovne inteligencije postala neizbježna za kvalitetno i efikasno vođenje poslovanja i donošenje odluka, međutim, primjenom alata poslovne inteligencije dobivaju se velike količine informacija pa primjena standardnih izvještaja kakvi su se prije implementacije ovih rješenja koristili više nije moguća. Iz navedenog razloga, zajedno s razvojem rješenja za poslovnu inteligenciju, dolazi i do razvoja alata za prezentaciju prikupljenih i obrađenih podataka, odnosno informacija. Poslovna inteligencija, u usporedbi s tradicionalnim načinom izvještavanja, unaprijeđena je karakteristikama kao što su interaktivnost, hijerarhijska organizacija sadržaja i multidimenzionalnost. Interaktivnost alata poslovne inteligencije omogućava korisniku da gotovo trenutno dobije povratnu informaciju na sva dodatna pitanja na koja naiđe prilikom pregledavanja izvještaja. Hijerarhijska organizacija omogućava prikaz podataka različite granularnosti, odnosno prikaz različite

¹ MIT software <http://www.mit-software.hr/usluge/bi/bi1/> (4.5.2017.)

² Barth, Paul: „The rise of the data marketplace“, <http://www.cio.com/article/3184575/business-intelligence/the-rise-of-the-data-marketplace.html> (9.5.2017.)

razine detalja, ovisno o potrebama korisnika. Multidimenzionalnost korisniku daje mogućnost da prikupljene podatke sagleda na različite načine te ih usporedi iz drugačijih perspektiva³.

Trendovi poslovne inteligencije konstantno se mijenjaju, a alati unaprjeđuju novim značajkama. Trend vizualizacije podataka od iznimnog je značaja zato što korisnicima omogućava lak pristup podacima te jednostavno i brzo razumijevanje trendova u poslovanju. Interaktivna, jednostavna i grafička sučelja najznačajniji su element sustava poslovne inteligencije koji analizirane podatke vizualno predočava korisniku u obliku jednostavnih grafičkih usporedbi, a većina alata ostavlja i mogućnost izbora načina prikaza podataka. Vizualni izvještaj koji korisnik jednostavno može mijenjati u skladu sa svojim preferencijama i potrebama zasigurno je, uz pravovremene i točne podatke, glavna prednost korištenja sustava poslovne inteligencije u poslovanju. Jednostavna i točna prezentacija podataka, uz izvještaje u realnom vremenu u današnje vrijeme nezamjenjivi su za donošenje poslovnih odluka, upravljanje organizacijom i ostvarivanje konkurentske prednosti⁴. Danas postoji veliki broj alata za vizualizaciju podataka, međutim, nekoliko ih se ističe kao najčešće korišteni. Prema svjetskim ljestvicama najpopularniji je softver Tableau, a odmah iza njega nalazi se Microsoft Power BI i Qlik. Popularni su još i SAP, Pentaho, Oracle, Domo, IBM, Sisense, Looker i drugi. Unatoč velikom broju popularnih alata, svaka organizacija trebala bi se odlučiti za onaj koji najbolje zadovoljava njene potrebe. Svi ovi alati i mnogi drugi obavljaju istu funkciju, vizualizaciju obrađenih podataka koja omogućuje lakše uočavanje trendova te bolje i efikasnije donošenje odluka. Stoga se ne može reći da je jedan alat bolji od drugog, već samo da bolje zadovoljava potrebe pojedine organizacije koja ga primjenjuje⁵.

1.2. Predmet istraživanja

Poslovna inteligencija širok je pojam koji obuhvaća raznovrsne metodologije i alate. Alati poslovne inteligencije koriste se primarno za analizu podataka, zatim rudarenje podataka,

³ MIT software <http://www.mit-software.hr/usluge/bi/bi1/> (4.5.2017.)

⁴ Lebed, Mona: „Top 11 Business Intelligence and Analytics Trends for 2017“ <http://www.datapine.com/blog/> (4.5.2017.)

⁵ Harris, Daniel: „FrontRunners for Business Intelligence“, <http://www.softwareadvice.com/bi/#top-products> (4.5.2017.)

pohranu i vizualizaciju istih⁶. Ovaj rad pristupiti će problemu vizualizacije podataka, primarno alatima koji se koriste u svrhu vizualizacije. Vodeći alati koji će se uspoređivati su SAP, Tableau, Microsoft Power BI, Pentaho, Oracle, Qlik, IBM. Kroz usporedbu funkcionalnosti navedenih alata nastojat će se objasniti uloga vizualizacije podataka te njezin doprinos u donošenju poslovnih odluka, kao i utjecaj na razumijevanje analiziranih podataka⁷. Nakon predstavljanja poznatih svjetskih alata pristupit će se analizi korištenja istih u Hrvatskoj. Kako bi se došlo do relevantnih zaključaka bit će provedeno istraživanje o primjeni svakog od pojedinih alata u hrvatskim organizacijama, te usporedba načina na koje te organizacije posluju i donose poslovne odluke, i u kojoj mjeri i na koji način koriste alate za vizualizaciju podataka. Analiza pojedinih hrvatskih alata za vizualizaciju te njihova primjena u poslovanju omogućit će usporedbu karakteristika najpoznatijih svjetskih alata s hrvatskim, kako bi se uvidjele međusobne prednosti ili nedostaci. Nakon cjelokupnog istraživanja bit će iznesen zaključak o problemima na koje organizacije nailaze prilikom korištenja alata za vizualizaciju podataka⁸.

2.1. Istraživačka pitanja

U odnosu na definirani problem i predmet istraživanja, postavljena su istraživačka pitanja na koja će ovaj rad dati odgovor:

- Jeli vizualizacija podataka utječe na razumijevanje analiziranih podataka i donošenje poslovne odluke?
- Na koji način vizualizacija podataka utječe na kratkoročno i dugoročno poslovanje organizacije?
- Jesu li alati za vizualizaciju značajan čimbenik prilikom donošenja poslovnih odluka?
- Koje funkcionalnosti alata za vizualizaciju su najznačajnije za unaprjeđenje poslovanja?

⁶ Dholakiya, Pratik: „Look for These 5 Business Intelligence Tool Attributes to Effectively Drill Into Big Data“, <https://www.entrepreneur.com> (4.5.2017.)

⁷ Davis, Jessica: „10 Data Visualization Tools To Bring Analytics Into Focus“, <http://www.informationweek.com> (9.5.2017.)

⁸ Bosilj V., Vesna; Ćurko, K.; Merkaš, Z.: „Usage of Business Intelligence technology in Croatia: Preliminary research“, <http://www.wseas.org/cms.action> (19.5.2017.)

- Na koji način i u koje svrhe se poznati svjetski alati koriste u Hrvatskim organizacijama?
- Kako bi korištenje alata za vizualizaciju moglo unaprijediti poslovanje Hrvatskih tvrtki?
- Koji su hrvatski konkurenti poznatim svjetskim alatima za vizualizaciju?
- Na koji način se hrvatski alati za vizualizaciju mogu unaprijediti kako bi konkurirali na stranim tržištima?
- Koji su osnovni problemi na koje organizacije nailaze kada je u pitanju vizualizacija podataka?

2.2. Ciljevi istraživanja

Na temelju predmeta i problema istraživanja te istraživačkih pitanja kao glavni cilj ovog istraživanja može se definirati utvrđivanje pojma vizualizacije podataka i njene uloge u poslovanju organizacije u svijetu i Hrvatskoj, kroz koristi koje proizlaze iz primjene alata za vizualizaciju u poslovanju. Kao ostale ciljeve može se izdvojiti definiranje najznačajnijih karakteristika ovih alata koje doprinose poboljšanju poslovanja, te utvrđivanje na koji se način svjetski alati za vizualizaciju koriste u Hrvatskoj i kako utječu na konkurentnost istih na svjetskom i domaćem tržištu.

Uloga alata za vizualizaciju iznimno je značajna kada se radi o razumijevanju podataka s kojima organizacija raspolaže, kao i prilikom donošenja poslovnih odluka. Danas se sve više važnosti pridaje kvalitetnim alatima za vizualizaciju jer organizacije počinju shvaćati značaj kvalitetnog prikaza podataka. Činjenica je da organizacije koje koriste alate za vizualizaciju podataka značajno bolje upravljaju informacijama i donose bolje odluke u odnosu na organizacije koje koriste standardne izvještaje. Primjena ovih alata Hrvatskim bi poduzećima trebala osigurati mogućnost kvalitetnijeg iskorištavanja podataka koji su neophodni kako bi konkurirali na svjetskom tržištu.

Iz cjelokupnog rada zaključiti će se i koji su najčešći problemi s kojima se organizacije susreću prilikom odabira, implementacije i korištenja alata za vizualizaciju, primarno u Hrvatskoj. Razotkrivanje ovih problema značajno je kako bi se mogli otkriti razlozi zbog

kjih su poduzeća neodlučna po pitanju korištenja alata za vizualizaciju podataka, te definirati načini na koje bi se ti problemi mogli izbjeći.

2.3. Metode istraživanja

- Induktivna metoda - na temelju analize pojedinačnih činjenica donosi se zaključak o općem sudu.
- Metoda dedukcije - koristi se za donošenje zaključaka.
- Metoda sinteze - povezivanje jednostavnih misaonih tvorevina u složenije.
- Metoda generalizacije - isticanje onog što je najbitnije.
- Metoda klasifikacije i komparacije - usporedba alata vršiti će se na temelju odabranih kriterija, uspoređujući alate međusobno s obzirom na kriterije koji su postavljeni, te uočavanjem sličnosti i različitosti alata.
- AHP metoda (Analitički Hijerarhijski Proces)- provođenje višekriterijalne analize na temelju postavljenih kriterija za usporedbu i vrednovanje alata za vizualizaciju podataka
- Metoda deskripcije- opisivanje i ocrtavanje funkcionalnosti, kriterija i ostalih karakteristika alata koji će se analizirati i uspoređivati u radu
- Metoda intervjua – razgovor sa ekspertom na području vizualizacije kako bi se ustanovili problemi, prednosti i stekao dublji uvid u cjelokupno područje.

2.4. Doprinos istraživanja

Osnovni znanstveni doprinos ovog rada biti će usporedba svjetski poznatih alata, izdvajanje njihovih prednosti i nedostataka te definiranje važnosti vizualizacije podataka u poduzeću. Također značajan doprinos biti će i definiranje problema na koji poduzeća nailaze prilikom korištenja alata, a samim tim utvrditi će se koje karakteristike koje bi se trebale promijeniti kako bi veći broj poduzeća pristupio korištenju vizualizacije u poslovanju. Utvrditi će se i način na koji vizualizacija podataka osigurava konkurentsku prednost organizacija, a sve u svrhu definiranja značaja korištenja alata za vizualizaciju.

2.5. Struktura diplomskog rada

Diplomski rad strukturiran je u obliku šest poglavlja kroz koja će se izložiti istraživanje. U uvodnom dijelu predstaviti će se problem i predmet istraživanja te istraživačka pitanja. Definirati će se njegova svrha i ciljevi te metode koje će se koristiti prilikom provođenja istraživanja. Također će se izložiti i struktura diplomskog rada, te njegov sadržaj.

U drugom poglavlju predstaviti će se teorijski aspekt poslovne inteligencije kako bi se bolje stekao uvid u ulogu vizualizacije kao dijela poslovne inteligencije. Objasniti će se i njena primjena u poslovanju te će se razraditi i aktualni trendovi na području poslovne inteligencije, sve u svrhu definiranja značaja vizualizacije podataka u odnosu na ostale funkcionalnosti sustava poslovne inteligencije. Na posljepku će se razraditi i načini te obuhvat primjene poslovne inteligencije u Hrvatskoj.

U trećem poglavlju obraditi će se područje vizualizacije podataka. Definirati će se vizualizacija podataka u sustavu poslovne inteligencije, nakon čega će se razraditi vizualizacija podataka unutar poduzeća, odnosno načini na koje se ista primjenjuje u organizacijama. Potom će se razmatrati utjecaj koji primjena alata za vizualizaciju ima na poslovanje poduzeća. U konačnici obraditi će se i primjena alata za vizualizaciju u Hrvatskoj, kako bi se utvrdilo na koji način ovi alati unaprjeđuju poslovanje hrvatskih organizacija.

Svjetski alati za vizualizaciju obraditi će se **u četvrtom poglavlju**. Ovdje će se definirati osnovne karakteristike alata za vizualizaciju, izdvojiti će se i objasniti najpoznatiji i naj češće korišteni alati. Potom će se navedeni alati uspoređivati kako bi se izdvojile i objasnile najznačajnije prednosti, ali i nedostaci. Kao posljednja stavka ovog poglavlja biti će izdvojeni alati za vizualizaciju razvijeni u Hrvatskoj te će se isti usporediti sa svjetskim alatima na temelju čega će se donijeti zaključak o mogućnosti konkuriranja.

Peto poglavlje definirati će primjenu alata za vizualizaciju u Hrvatskoj. Obraditi će se primjena svjetskih alata u hrvatskim poduzećima, karakterizirati će se načini primjene istih u poslovanju te će se istražiti kako njihova primjena utječe na poslovanje organizacije. Na posljepku će se izdvojiti i objasniti osnovni problemi sa kojima se susreću hrvatska poduzeća prilikom primjene alata za vizualizaciju.

U **šestom poglavlju** iznijeti će se zaključci nastali kao rezultat provedenog istraživanja te će se definirati i smjernice kako bi se poboljšali postojeći alati za vizualizaciju te omogućila šira primjena istih.

1. Poslovna inteligencija

2.6. Poslovna inteligencija i njena primjena u poslovanju

Poslovna inteligencija obuhvaća široki skup alata i metodologija kojima se organizacijama omogućava prikupljanje podataka, obrada i pohrana istih, te korištenje dobivenih informacija kako bi se donosile efikasne odluke za poduzeće i osigurao napredak organizacije.

Možemo reći da je poslovna inteligencija ključna sastavnica poslovanja u današnje vrijeme, a služi kako bi se kreirala i ostvarila operativna učinkovitost organizacije. Korištenjem podataka iz realnog vremena, uz analizu povijesnih podataka, ona omogućuje donošenje kvalitetnih poslovnih odluka, identifikaciju poslovnih problema i načina za njihovo rješenje.⁹

2.6.1. Poslovna inteligencija

Poslovna inteligencija proces je analize podataka na temelju kojeg se dobivaju korisne i pravovremene informacije koje pomažu direktorima, poslovnim menadžerima i drugim korisnicima unutar organizacije da donose kvalitetne poslovne odluke u pravo vrijeme. Na ovaj način organizacija je u mogućnosti na vrijeme uvidjeti promjene u svom okruženju i na njih adekvatno reagirati kako bi ostala konkurentna na tržištu.

Poslovna inteligencija obuhvaća niz alata, metodologija i aplikacija koje organizaciji omogućavaju prikupljanje velikih količina podataka iz sustava unutar organizacije i izvora u vanjskom organizacijskom okruženju. Prikupljeni podaci se pripremaju za obradu, analiziraju i pohranjuju u skladišta podataka. Prilikom analize podataka koriste se i kombiniraju različite metode i alati.

⁹ Heinze J. „Business Intelligence vs. Business Analytics: What’s The Difference?“
<https://www.betterbuys.com/bi/business-intelligence-vs-business-analytics/> (24.7.2017.)

Kako bi se u što kraćem vremenu obradile velike količine podataka i zadovoljile potrebe za sve složenijim analitičkim upitima, koristi se OLAP sustav, dio poslovne inteligencije koji služi za podršku analizi poslovnih procesa (*eng. OnLine Analytical Processing*). OLAP sustav provodi višedimenzijску analizu podataka i na taj način osigurava mogućnost izvođenja zahtjevnih analiza nad podacima, kao što su analiza trendova i modeliranje podataka. Ovi sustavi koriste ad hoc analizu kako bi se korisniku omogućilo dobivanje specifičnih informacija u najkraćem mogućem vremenskom roku.

Rezultati analiza nad podacima korisnicima se prezentiraju u obliku izvještaja i grafikona, koji mogu biti standardizirani, ako se radi o standardiziranim upitima. Ili mogu biti specifični, odnosno korisnik sam može odlučiti koje rezultate želi vidjeti i na kakav način želi da oni budu prikazani. Kako bi se rezultati složenih analiza prezentirali na razumljiv, logičan i što jednostavniji način izvještaji su najčešće sastavljeni od niza tablica i grafikona koji prikazuju međuovisnosti i trendove. Ovakav prikaz rezultata analize predstavlja još jedan dio poslovne inteligencije, nazvan vizualizacija podataka.¹⁰ Iz prethodno navedenog možemo zaključiti kako je vizualizacija podataka iznimno značajna karakteristika poslovne inteligencije, koja omogućava korisnicima razumijevanje analiziranih podataka, povezivanje rezultata i donošenje relevantnih zaključaka.

2.6.2. Primjena poslovne inteligencije u poslovanju

U današnje vrijeme ključni čimbenik za opstanak na tržištu je pravovremena i točna reakcija na konstantne promjene koje se događaju u vanjskom i unutarnjem okruženju organizacije. Ove promjene su svakodnevne i uzrokuju propast organizacija koje ih ignoriraju ili na njih ne reagiraju na vrijeme. Istovremeno, organizacije koje na vrijeme uvide promjene i na njih adekvatno reagiraju postaju tržišni predvodnici. Poslovna inteligencija skup je alata koji organizaciji omogućavaju da prikupi podatke s tržišta i te podatke pretvori u korisne informacije kako bi mogla utvrditi promjene u okruženju i na njih adekvatno reagirati.

Mala i srednja poduzeća, iako svjesna da je informacija ključna za uspjeh na tržištu, čak i danas jako teško pristaju na uvođenje sustava poslovne inteligencije u organizaciju. Ovaj

¹⁰ Rouse, M. „Business Intelligence (BI)“ <http://searchdatamanagement.techtarget.com/definition/business-intelligence> (24.7.2017.)

problem uglavnom se javlja zbog toga što su menadžeri i vlasnici loše informirani i ne znaju što je zapravo poslovna inteligencija te kako im može pomoći u poslovanju. Činjenica jest da čak i mala i srednja poduzeća mogu imati velike koristi od uvođenja sustava poslovne inteligencije. Dok manja poduzeća tek počinju shvaćati ulogu i koristi koje im poslovna inteligencija donosi, velika poduzeća i internacionalne organizacije posluju, šire se i zauzimaju nova tržišta, zahvaljujući prikupljanju i obradi podataka iz interne i eksterne okoline te efikasnom korištenju dobivenih informacija u poslovne svrhe.

Brojni su načini primjene poslovne inteligencije u poslovanju, a u ovisnosti o načinu primjene razlikuje se i njezin utjecaj na poslovanje poduzeća. Poslovna inteligencija kod velikih se organizacija koristi za praćenje stanja na tržištu i događanja unutar same organizacije kako bi reagirali na promjene i ostali na vodećim pozicijama ili došli do istih. Ove organizacije prikupljaju velike količine podataka, obrađuju ih i iz njih dobivaju informacije o stanju na tržištu te procesima i aktivnostima unutar organizacije. Manje organizacije mogu implementirati znatno manje komplicirane sustave koji će zadovoljavati sve njihove potrebe i osigurati im da se istaknu na svom tržištu.

Uvođenje poslovne inteligencije u poslovanje omogućuje organizacijama, velikim i malim, da na bolji i efikasniji način analiziraju trendove na ciljnom tržištu i na taj način prilagode svoju ponudu kako bi odgovarala potrebama i željama kupaca. Praćenje stanja na tržištu ključno je kako bi se primijenila odgovarajuća marketinška strategija koja će privući točno onu skupinu kupaca koju organizacija cilja.

Primjena poslovne inteligencije poduzeću pomaže i da se istakne na tržištu. Analiziranjem konkurenata mogu se utvrditi njihove mane i slabosti ali i snage, te na taj način poboljšavati poslovanje svoje organizacije kako bi ostali konkurentni. Analiza internog stanja, procesa u organizaciji, načina poslovanja i troškova dovodi do optimizacije procesa unutar poduzeća, a posljedično i do bolje kontrole organizacije.

Primjena poslovne inteligencije u poduzeću dovodi do mogućnosti planiranja i praćenja razvoja poduzeća, stanja u njegovoj okolini i mogućnosti pravilne reakcije na promjene. Sustav poslovne inteligencije organizaciji omogućuje da iz velike količine podataka uoči

uzorke i trendove u poslovanju te da na temelju tih informacija donese bolje i kvalitetnije poslovne odluke.¹¹

2.7. Trendovi u poslovnoj inteligenciji

Tehnologija se u današnje vrijeme mijenja iz dana u dan, ono što je jučer bilo aktualno danas je možda već zastarjelo. Živimo u vremenu u kojem se trendovi i tehnologija konstantno mijenjaju, poboljšavaju i nadograđuju. Kako se poslovna inteligencija temelji na informatičkoj tehnologiji logično je zaključiti da će se s napretkom tehnologije mijenjati i tehnološki aspekt poslovne inteligencije. Međutim, kako poslovna inteligencija ima i metodološki aspekt, bitno je naglasiti da se, razvojem novih sustava i načina prikupljanja, obrade i analize podataka, događaju promjene i na ovom području.

U posljednjih nekoliko godina došlo je do pojave novih trendova u IT području, a neki od njih su digitalizacija, agilnost, sigurnost, analitika, mobilnost, umjetna inteligencija i tehnologija u oblaku. Ovi trendovi oblikuju budućnost poslovne inteligencije, odnosno mijenjaju načine poslovanja poduzeća i time definiraju nove standarde koje poslovna inteligencija u poduzeću treba zadovoljavati. Upravo iz ovog razloga dolazi do promjene trendova u poslovnoj inteligenciji.

Istraživanje trendova na području trendova poslovne inteligencije koje je proveo BARC, na temelju uzorka od 2772 korisnika, pokazalo je da su sljedeći trendovi poslovne inteligencije najznačajniji za 2017. godinu.

Prvi i najznačajniji trend u ovoj godini je vizualizacija podataka, koja obuhvaća pripremu podataka, vizualizaciju i naprednu analizu podataka kako bi se došlo do novih informacija koje će korisniku biti potrebne i razumljive. Zaključeno je da su novi načini vizualizacije podataka potrebni kako bi korisnici mogli imati pristup svim informacijama koje su im potrebne za donošenje ispravne poslovne odluke. Bitno je naglasiti da u vizualizaciju podataka spada i vizualna analiza kojom se poboljšava razumijevanje informacija i rezultata provedenih analiza ali i daje mogućnost korisniku da sam dođe do pojedinih zaključaka i

¹¹ Al-Hassani, Yass „Why is BI important to your company?“ <https://www.linkedin.com/pulse/why-business-intelligence-bi-important-your-company-yass> (24.7.2017.)

istraži problem detaljnije kako bi bolje razumio dobivene rezultate. Dokazano je da ljudi bolje razumijevaju informacije koje su im prezentirane u obliku dijagrama i grafova u odnosu na prezentaciju u tablicama. Organizacije su shvatile da se korištenjem vizualizacije podataka donose bolji zaključci koji vode ka boljim poslovnim odlukama, što je ujedno i razlog za prvo mjesto ovog trenda.


Drugi trend je self-serivice BI, odnosno potreba da svi korisnici kojima su podaci potrebni mogu samostalno koristiti sustav poslovne inteligencije kako bi dobili sve informacije koje su im potrebne kako bi adekvatno obavljali svoje poslove. Self-service BI između ostalih karakteristika obuhvaća korištenje vizualizacije, prediktivne analitike i analizu trendova. Ovdje dolazi do problema kontrole podataka, za koju je iznimno bitno da se utvrde pravila u vezi sa korištenjem, prikupljanjem i analizom podataka. Kako je danas potreba za brzim pristupom točnim informacijama sve veća, razumljivo je da je ovaj trend u samom vrhu ljestvice potreba poduzeća.

Treći trend je Data Quality Management i Master Data Management, koji se odnose na potrebu za kvalitetnim podacima kao i potrebu za prikupljanjem podataka iz različitih izvora koji koriste različite sustave. Naime informacije su beznačajne ukoliko nisu točne i kvalitetne, jer ako se na temelju loših informacija donose poslovne odluke one ne mogu biti dobre i efikasne za poduzeće. Ne kvalitetni podaci dovode do toga da se sustav poslovne inteligencije uopće ne koristi zbog toga što zaposlenici nemaju povjerenje u informacije koje iz njega dobivaju. U današnje vrijeme, kada se generiraju i prikupljaju velike količine podataka teško je zaključiti koji podaci su kvalitetni a koji ne, stoga je ovo poseban izazov za poslovnu inteligenciju.

Četvrti trend odnosi se na trend analitičkih baza podataka. To su baze podataka specijalizirane za analitiku, mogu biti u obliku softvera ili kao jedna primjena skladišta podataka. Ako se radi o skladištu podataka ove baze su kombinacija hardvera i softvera koja osigurava uravnoteženi sustav za bolju i lakšu upotrebu u analitičke svrhe. Osnovne prednosti analitičkih baza podataka su brže izvršavanje upita koji se postavljaju prema bazi podataka, lakše održavanje i skalabilnost (nadogradnja). Ako se uzme u obzir rastuća potreba za informacijama unutar organizacije kao i potreba za sve kompleksnijom analizom podataka lako je zaključiti da

dolazi i do potrebe za naprednijim i bržim sustavima koji će u kraćem vremenu moći izvoditi zahtjevne analize nad podacima.¹²

Slika 1 prikazuje sve trendove poslovne inteligencije u 2017. godini za koje je BARC provodio istraživanje. Trendovi su ocjenjeni ocjenama od 1 za najmanje bitne trendove do 10 za jako važne trendove u poslovnoj inteligenciji. Ocjene su dodijeljene od strane 2772 korisnika i stručnjaka na području poslovne inteligencije.



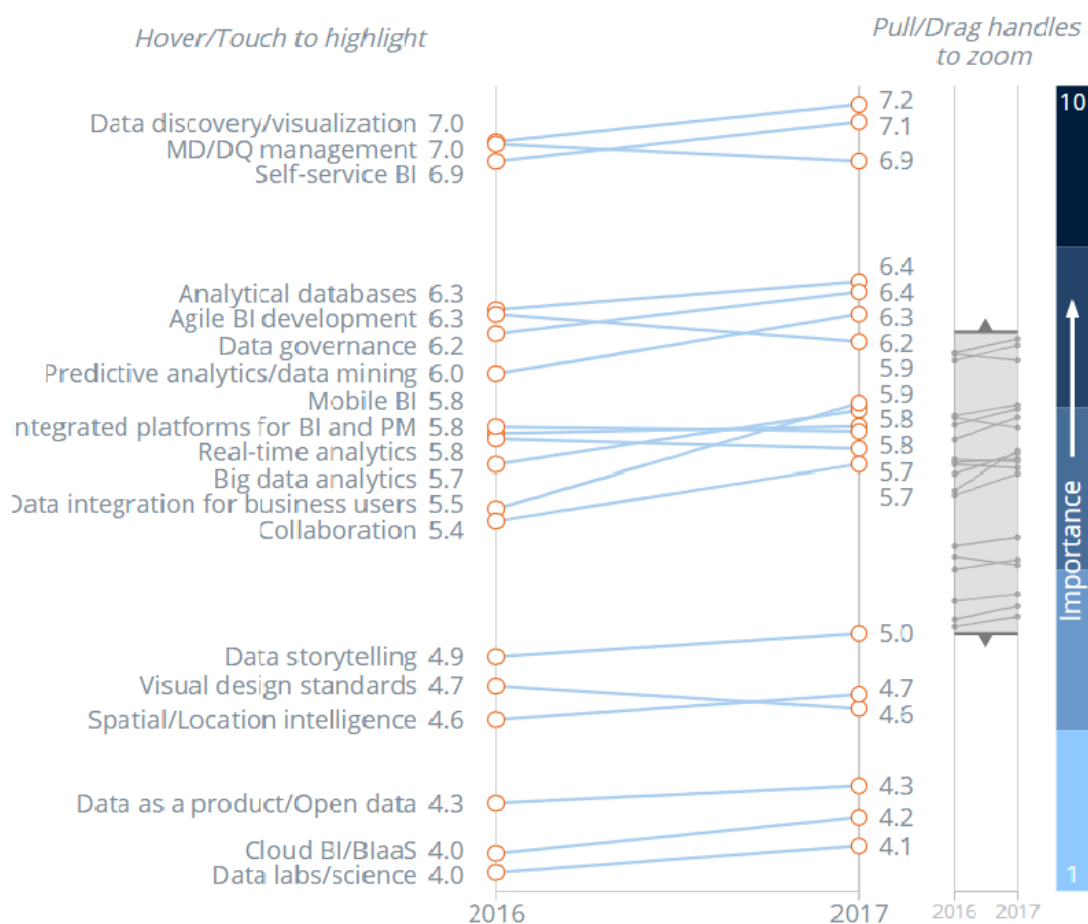
Slika 1. Važnost trendova poslovne inteligencije u 2017. godini

Izvor: <https://bi-survey.com/top-business-intelligence-trends-2017>

Slika 2 prikazuje usporedbu trendova u 2016. godini sa trendovima u 2017. godini. Iz slike možemo vidjeti da su u 2016. godini bila dva trenda na prvom mjestu i stručnjaci i korisnici su ih smatrali jednako važnima, ti trendovi su data discovery/vizualizacija podataka i Master Data Management/ Data Quality Management. U 2017. godini međutim dolazi do porasta potrebe za vizualizacijom podataka i omogućavanja postavljanja upita i analize podataka

¹² BI-SURVEY „Top Business Intelligence Trends 2017: What 2,800 BI Professionals Really Think“ <https://bi-survey.com/top-business-intelligence-trends-2017> (24.7.2017.)

korisnicima koji nemaju široko informacijsko-tehnološko znanje. Također se trend self-service BI, koji se nastavlja na prvi trend vizualizacije, mijenja i prelazi na drugo mjesto u 2017. godini. Dok trend Master Data Management i Data Quality Management pada na treće mjesto.



Slika 2. Usporedba važnosti trendova u 2016. i 2017. godini

Izvor: <https://bi-survey.com/top-business-intelligence-trends-2017>

Razlog ovim promjenama može se pronaći u činjenici da su organizacije shvatile da nema smisla imati pristup velikoj količini kvalitetnih podataka ako ih osobe zadužene za donošenje odluka ne mogu samostalno istraživati i zaključivati. Dakle može se zaključiti da je vizualizacija podataka ključan čimbenik u iskorištavanju podataka i informacija, jer uz pomoć vizualizacije odgovorne osobe mogu donositi informirane odluke, ali i pristupiti informacijama, istražiti problem i razumjeti uzročno posljedične veze na temelju kojih donose te odluke.

2.8. Poslovna inteligencija u Hrvatskoj

Primjena poslovne inteligencije u velikim i srednjim poduzećima u današnje vrijeme postala je neizbježna, kako u svijetu tako i u Hrvatskoj. Danas sve veće organizacije primjenjuju barem neki oblik poslovne inteligencije kako bi organizirali i usmjerili poslovanje svog poduzeća prema ostvarenju dugoročnih ciljeva.¹³ U posljednjih nekoliko godina počela se sve više razvijati svijest o poslovnoj inteligenciji među donositeljima odluka u manjim poduzećima, a s tim došlo je i do sve veće cjenovne prihvatljivosti tehnologije poslovne inteligencije što je uzrokovalo sve veću primjenu i kod manjih poduzeća. Tako danas gotovo ne postoji poduzeće u svijetu koje ne koristi alate poslovne inteligencije, a još uvijek je konkurentno na tržištu.

U Hrvatskoj, kao i u svijetu, sve organizacije koje žele ostati konkurentne na tržištu moraju pratiti promjene i prilagođavati im se, u suprotnom dolazi do zaostajanja organizacije u odnosu na konkurente i u konačnici prekida poslovanja. Istraživanje provedeno 2013. godine utvrdilo je da velika većina organizacija, njih čak 82% koje posluju na hrvatskom tržištu, koristi skladišta podataka. U odnosu na svjetskih 90% organizacija koje koriste skladišta podataka može se zaključiti da je postotak primjene u Hrvatskoj zadovoljavajući. Prema istom istraživanju 73% poduzeća koja koriste skladišta podataka koriste i OLAP sustave, ali samo 10% poduzeća koristi tehnike rudarenja podataka.¹⁴

Poslovna inteligencija u Hrvatskoj se primjenjuje u raznim oblicima, a najčešći je putem Google Analytics-a i uz korištenje Excel tablica, ali sve više poduzeća počinje koristiti alate koji će im pomoći u izvlačenju podataka iz brojnih excel tablica, mailova i spominjanja na društvenim mrežama i u online svijetu općenito. Ovi alati organizacijama služe kako bi smanjili vrijeme potrebno za izradu potrebnih izvještaja i kako bi imali pristup potrebnim informacijama u najkraćem mogućem roku. Organizacije u Hrvatskoj počele su uviđati da bez ovakvih sustava ne mogu imati točnu informaciju u potrebnom vremenu te se danas sve više

¹³ Pejic Bach, M., Strugar, I., Simicevic, V. „Determinants of business intelligence usage in Croatian large companies“, Beč, 2010. <http://www.freepatentsonline.com/article/Annals-DAAAM-Proceedings/246013830.html>

¹⁴ Ćurko, K., Bosilj Vukšić V., Merkaš Z. „Usage of Business Intelligence technology in Croatia: Preliminary research“, WSEAS TRANSACTIONS on BUSINESS and ECONOMICS, 2016., V13

primjenjuju sustavi poslovne inteligencije u svakodnevnom poslovanju, ali i za donošenje važnih poslovnih odluka kao i za strateško planiranje poduzeća.¹⁵

Do danas prethodno navedeni brojevi su se značajno povećali. Brojne organizacije implementirale su sustave poslovne inteligencije u svoje poslovanje kako bi se mogle nositi sa konkurencijom i iskorištavati informacije sa tržišta u korist svojeg poslovanja. Velike organizacije u Hrvatskoj primjenjuju vlastite sustave poslovne inteligencije, sami prikupljaju ili kupuju podatke te ih obrađuju i iskorištavaju dobivene informacije kako bi pratile stanje na tržištu i usmjeravale svoje poslovanje na strateškoj i operativnoj razini. Manje organizacije koriste specijalizirana poduzeća kao što su konzultantska tvrtka Bisnode, koja za njih obavlja usluge prikupljanja i analize podataka, te svojim klijentima isporučuje gotove informacije na temelju kojih oni donose poslovne odluke. Outsourcing usluga poslovne inteligencije je kod manjih poduzeća neophodan zbog potrebe za točnim i kvalitetnim informacijama ali i nedostatka tehnološke infrastrukture te kadra ljudi koji je potreban za implementaciju sustava poslovne inteligencije.¹⁶

U korist činjenice da je u Hrvatskoj primjena sustava poslovne inteligencije u konstantnom porastu govori i prihod Adacte, najvećeg Microsoftovog partnera u implementaciji ERP rješenja u Hrvatskoj. Ova organizacija svoj uspjeh doživjela je zbog sve veće potražnje za rješenjima na području poslovne inteligencije i upravljanja odnosa s korisnicima. Na tržištu u Hrvatskoj Adacta d.o.o. posluje već 25 godina, ali u 2015. godini doživjela je preokret. Naime tijekom ove ključne godine Adacta je povećala svoj prihod za dva i pol puta, a najveći dio tih prihoda došao je od implementacije rješenja za poslovnu inteligenciju. U 2015 godini Adacta je odradila više od 80 projekata implementacije rješenja za poslovnu inteligenciju. Njihovo PI rješenje temeljeno je na Quilk platformi koja je u istoj godini bila među leader-ima na tržištu. Quilk je tako uz pomoć Adacte implementiran u poduzeća kao što su Billa, Zoo Hobby,

¹⁵ Smolic H. „Doznajte što se zapravo krije iza pojma “Business Intelligence/Poslovna inteligencija”“, 2012., Poslovni Plus <http://www.poslovnipuls.com/2012/10/10/business-intelligence-poslovna-inteligencija/> (2.8.2017.)

¹⁶ Bičak D. „Danas sve ozbiljne tvrtke provjeravaju svoje buduće poslovne partnere, a mi smo njihove oči i uši“, Poslovni Dnevnik, 2016. <http://www.poslovni.hr/poduzetnik/danas-sve-ozbiljne-tvrtke-provjeravaju-svoje-buduće-poslovne-partnere-a-mi-smo-njihove-oci-i-usi-315266> (2.8.2017.)

Renault Nissan Hrvatska, Di Wagneru i Fortuna Komersu te u lancu restorana Marche i to na regionalnom nivou.¹⁷

3. Vizualizacija podataka

Danas je jedan od najvažnijih resursa za opstanak organizacija pravovremena i točna informacija. Do informacija organizacije dolaze na različite načine, ali te informacije nalaze u sve većim tablicama sa mnogo podataka od kojih je teško izabrati one koje su važne i korisne od onih koje su nepotrebne. Također teško je uočiti bilo kakve vrste uzoraka i trendova te odabrati one informacije koje su nam zapravo značajne. Organizacije posluju u svijetu u kojem se prikupljaju i analiziraju jako velike količine informacija svaki dan, te im je potreban alat uz pomoć kojega će moći brzo i lako razvrstati informacije te pristupiti točno onima koje su im potrebne u danom trenutku. Upravo ovakav pristup doveo je do razvoja alata za vizualizaciju podataka. Organizacije su shvatile da pravovremene i kvalitetne informacije same po sebi nisu dovoljne, već da je potrebno da donositelji odluka razumiju informacije kojima raspolažu i da im mogu pristupiti u svakom trenutku te ih detaljnije istražiti u svrhu donošenja boljih odluka za poslovanje poduzeća. Informacija je beskorisna ukoliko je osobe kojima je potrebna ne mogu koristiti. Ovdje leži osnova za primjenu vizualizacije podataka.

3.1. Vizualizacija podataka kao dio poslovne inteligencije

Poslovna inteligencija je, kao što je već navedeno, široko područje, a vizualizacija podataka je uz skladišta podataka, OLAP sustave i alate za analitiku, njen najznačajniji dio. Samo uz korištenje alata za vizualizaciju podataka organizacija može u potpunosti iskoristiti velike količine informacija kojima raspolaže.

Vizualizacija podataka predstavlja grafički ili bilo koji drugi, vizualni prikaz skupine podataka. Od davnih vremena, još od 17. stoljeća, ljudi koriste vizualizaciju kako bi predložili kompleksne probleme i podatke. U to vrijeme vrhunac vizualizacije bili su grafikoni, ali značajan napredak tehnologije omogućio je i napredak vizualizacije podataka kako bi se razvila u ono što se danas smatra vizualizacijom. Razvoj računalne tehnologije omogućio je

¹⁷ Ivezić B. „BI i CRM projekti ojačali Adactu“, Poslovni Dnevnik, 2016. <http://www.poslovni.hr/tehnologija/bi-i-crm-projekti-ojacali-adactu-310214> (2.8.2017.)

prikupljanje velike količine podataka koji je doveo do potrebe za analizom tih podataka kako bi bili iskoristivi organizacijama koje s njima raspolažu. Na taj način došlo je potrebe za razvojem i unaprjeđenjem poslovne inteligencije koja je omogućila da se ti podaci efikasno iskoriste i pohrane. Međutim sama analiza podataka nije dovoljna za organizacije, jer su se sada susrele sa problem razumijevanja i iskorištavanja dobivenih informacija. Naime, informacija ne vrijedi ništa ako je ne mogu iskoristiti ljudi kojima je potrebna za donošenje odluka i upravljanje organizacijom, u pravo vrijeme. Informacije koje su se dobivale kao rezultat analize u poslovnoj inteligenciji bile su prikazane u obliku statičnih izvještaja, teško razumljive i najčešće u obliku velikih tablica sa mnoštvom brojeva iz kojih je tek trebalo izvesti potrebne zaključke i tek nekoliko grafikona koji su prikazivali skupne rezultate. Dakle informacija je bila prisutna ali donositelji odluka je nisu mogli razumjeti bez pomoći analitičara, a samim tim i kada bi dobili pristup informaciji često je već bilo kasno za djelovanje na tom području. Zbog ovog problema pojavila se potreba za razvojem alata koji će podatke prikazati na jednostavan i razumljiv način, ali i omogućiti donositeljima odluka da detaljnije istraže problem, postavljaju upite i dodatno analiziraju rezultate kako bi donijeli kvalitetne odluke u pravo vrijeme. Na ovaj način dolazi do razvoja interaktivne vizualizacije podataka, koja osim prikaza rezultata objedinjuje i analitiku, pa korisnici mogu pristupiti skladištima podataka, postavljati dodatne upite i detaljnije istraživati pojedine stavke od interesa.¹⁸

Cilj vizualizacije podataka, kakvu danas znamo, jest stvaranje vizualne prezentacije velike količine podataka koja će biti jednostavno razumljiva korisniku i kojom će on po potrebi moći upravljati kako bi došao do željenih informacija. Vizualizacija podataka omogućava korisnicima prikaz analitičkih procesa u vizualnom, lako shvatljivom obliku kako bi mogli razumjeti koncepte koji su predstavljeni podacima ili uočiti uzorke nastanka odstupanja i veze među podacima, što bi bilo nemoguće napraviti sa tablicama u kojima je mnoštvo podataka prikazano u obliku brojeva smještenih u stupcima i redcima.

Uz vizualizaciju podataka usko se veže i pojam vizualne analize. Vizualna analiza zahtjeva od alata za vizualizaciju i primjenu analitike uz samo prikazivanje rezultata. Na ovaj način dolazi

¹⁸ TechTarget „Dashboard development and data visualization tools for effective BI“

<http://searchbusinessanalytics.techtarget.com/essentialguide/Dashboard-development-and-data-visualization-tools-for-effective-BI> (2.8.2017.)

do stvaranja interaktivne vizualizacije koja osim prikaza izvještaja u grafičkom i lako razumljivom obliku, korisniku omogućuje i upravljanje podacima na jednostavan način. Vizualna analiza predstavlja mogućnost da korisnik putem vizualnog sučelja samostalno oblikuje način prikaza podataka, postavlja upite i kreira nove izvještaje. Također ona omogućava korisniku i detaljniju analizu pojedinih podataka koji su im od posebnog značaja (*eng. Drill down*), a rezultate analiza vraća u vizualnom obliku. Uz to današnji alati za vizualizaciju podataka upozoravaju korisnika i kada se podaci promjene, što im omogućava konstantan pristup novim, aktualnim informacijama. Mogu se i unaprijed definirati uvjeti u slučaju ostvarenja kojih se odmah obavještava korisnika. Ovakav princip rada danas primjenjuju svi alati za vizualizaciju, uz pomoć interaktivnih sučelja (*eng. Dashboards*) o kojima će više biti rečeno u nastavku rada.¹⁹

Danas je vizualizacija podataka neizostavan dio svih modernih alata za poslovnu inteligenciju. Ne zamislivo je da će organizacije analizirati podatke kojima raspolažu pohraniti ih i potom ih neće iskoristiti, ili će pak iskoristiti samo mali dio kojem mogu pristupiti. Upravo zato vodeći svjetski dobavljači za rješenja poslovne inteligencije, Tableau i Qlik, svoje alate temelje upravo na vizualizaciji podataka. Oni isporučuju korisnicima kompletnu uslugu poslovne inteligencije uz kvalitetnu i jednostavnu vizualizaciju koja omogućava lako i brzo razumijevanje informacija koje nastaju kao rezultat kompleksnih analiza u sustavu poslovne inteligencije.

Vizualizacija podataka primjenjuje se ne samo u klasičnim sustavima poslovne inteligencije poduzeća, već je nezamjenjiv instrument i u analizi „velikih podataka“ (*eng. Big data*) kao i u naprednoj analitici (*eng. Advanced analytics*). Prilikom analize velikih količina podataka (*eng. Big data*) analitičarima i organizacijama potrebni su alati koji će brzo i jednostavno prikazati rezultate analize na razumljiv način. Također u naprednoj analitici (*eng. Advanced analytics*) vizualizacija podataka potrebna je kako bi se prilikom izrade različitih algoritama vizualizirali rezultati u svrhu praćenja napretka i osiguravanja kvalitetne izrade alata.²⁰

¹⁹ Blagović, L. „Vizualizacija podataka u sustavu poslovne inteligencije“, Sveučilište Jurja Dobrile u Puli, Pula, 2016., <https://dr.nsk.hr/islandora/object/unipu%3A794/datastream/PDF/view> (2.8.2017.)

²⁰ Rouse, M. „Data visualization“ <http://searchbusinessanalytics.techtarget.com/definition/data-visualization> (2.8.2017.)

3.1.1. Interaktivna sučelja (Dashboards)

Interaktivna sučelja sastavnica su svakog od današnjih alata za vizualizaciju podataka. Ona predstavljaju korisničko sučelje, jednostavne izrade, lako razumljivo i pregledno. Ovo korisničko sučelje način je korisnikove interakcije sa bazama podataka u skladištima podataka i osigurava mu mogućnost provođenja kvalitetnih analiza podataka. Nemaju svi korisnici, posebice ne prezaposleni menadžeri, potrebu ali ni želju prolaziti kroz dubinske analize podataka i gubiti vrijeme na pokušaje razumijevanja analitičkih procesa i mnoštva podataka. Stoga su interaktivna sučelja, sa grafovima, vizualnim prikazima, različitim pokazateljima i sustavima obavješćivanja idealna za ove korisnike kako bi na pojednostavljen način razumjeli proces analize podataka i cjelokupan koncept poslovne inteligencije koja se u organizaciji primjenjuje.

Međutim, izrada efikasnog interaktivnog sučelja, koje će sadržavati sve potrebne podatke, a da pritom ostane jednostavno uz sve važne stavke lako uočljive, problem je na kojeg dizajneri interaktivnih sučelja neprestano nailaze. Uz to, klijenti su najčešće direktori i menadžeri koji žele pristup što više informacija bez mnogo dodatnih analiza. Rješenje ovog problema leži u personalizaciji svakog od sučelja prema željama i potrebama korisnika, što je danas također standard prilikom izrade i implementacije alata za vizualizaciju.²¹

3.2. Uloga vizualizacije podataka u poduzeću

Poslovna inteligencija ima veliki potencijal za reorganizaciju poslovanja poduzeća, međutim problem se pojavljuje kod mjerenja rezultata. Ulaganja u alate poslovne inteligencije su značajna a rezultati nisu direktni, stoga su i teško mjerljivi. Organizacije se suočavaju s ne mogućnošću utvrđivanja koje su posljedice uvođenja sustava poslovne inteligencije u poslovanje, izuzev visokih troškova koji su pratili implementaciju. Ovdje pomaže vizualizacija podataka. Naime korištenjem alata za vizualizaciju organizacije mogu vidjeti u razumljivim oblicima čemu su to stekli pristup uvođenjem sustava poslovne inteligencije.

²¹ Stedman, C. „Dashboard tools lighten burdens on business users, but not BI teams“, <http://searchbusinessanalytics.techtarget.com/feature/Dashboard-tools-lighten-burdens-on-business-users-but-not-BI-teams> (2.8.2017.)


Također mogu jednostavno pratiti sve procese u poduzeću i brzo reagirati u skladu s promjenama.

Vizualizacija podataka organizacijama pruža mogućnost prikaza kompleksnih analiza na lako razumljiv način, uz to omogućava im i prikaze različitih scenarija u slučaju različitih odluka, uz vrlo jednostavnu manipulaciju podacima. Omogućava i identificiranje područja na kojima su potrebna unaprjeđenja ili na koje treba pripaziti kako ne bi došlo do kritičnih situacija. Pruža uvid u situaciju na tržištu i utvrđivanje razloga zbog kojih klijenti mijenjaju ponašanje te osigurava mogućnost pravovremene reakcije na promjene na ciljnom tržištu. Omogućava predviđanje prodaje i troškova temeljeno na povijesnim i aktualnim informacijama, te olakšava razumijevanje tržišta na kojem organizacija posluje, kako bi na efikasniji način plasirala proizvode u svrhu ostvarenja maksimalne dobiti.

Bilo da se radi o velikim, multinacionalnim organizacijama ili malim, lokanim poduzećima, svi skoriste vizualizaciju podataka kako bi razumjeli podatke kojima raspolažu. Postoji nekoliko najčešćih upotreba alata za vizualizaciju u organizacijama, kao što su korištenje za brzo razumijevanje informacija, za identificiranje uzoraka i odnosa, za identificiranje trendova u nastajanju te za informiranje okoline.

Razumijevanje informacija u vrlo kratkom vremenu. Korištenjem interaktivnih sučelja koje prikupljene i analizirane informacije prikazuju uz pomoć grafičkih i drugih vizualnih prikaza, organizacije mogu vidjeti veliku količinu informacija na jednom mjestu, prikazanu na jednostavan i lako razumljiv način. Na temelju ovako prezentiranih informacija vrlo je jednostavno donositi zaključke, pa je potrebno manje vremena za razumijevanje informacija kao i za djelovanje na temelju utvrđenog. Također, brže i jednostavnije se mogu vršiti dodatne analize koje su potrebne za dublje razumijevanje problema, jer je vizualna analiza jednostavnija a samim tim i brža od klasične analize podataka u tablicama. Sve navedeno omogućava organizaciji da reagira mnogo brže te da u kraćem vremenu donosi kvalitetne poslovne odluke. Na slici tri prikazan je jednostavan primjer vizualizacije podataka. Tu možemo vidjeti da je u tabličnom prikazu čak i na jako malom broju podataka teško uočiti ovisnosti, trendove i donijeti bilo kakve značajne zaključke. S druge strane na grafičkom prikazu jasno se vide trendovi i odnosi, te je jednostavno istražiti varijable koje se smatraju značajnima.

Age Group	Total Number of loans	Number of Bad loans	Number of Good Loans	Percentage Bad loans	Percentage Good Loans
<21	9	2	7	22.2%	77.8%
21-24	310	14	296	4.5%	95.5%
24-27	511	20	491	3.9%	96.1%
27-30	4000	172	3828	4.3%	95.7%
30-33	4568	169	4399	3.7%	96.3%
33-36	5698	188	5510	3.3%	96.7%
36-39	8209	197	8012	2.4%	97.6%
39-42	8117	211	7906	2.6%	97.4%
42-45	9000	216	8784	2.4%	97.6%
45-48	7600	152	7448	2.0%	98.0%
48-51	6000	84	5916	1.4%	98.6%
51-54	4000	64	3936	1.6%	98.4%
54-57	2000	26	1974	1.3%	98.7%
57-60	788	9	779	1.1%	98.9%
>60	6	0	6	0.0%	100.0%



Slika 3. Vizualizacija podataka

Izvor: <http://ucanalytics.com/blogs/data-visualization-case-study-banking/>

Identificiranje uzoraka i odnosa. U velikim bazama podataka prikazanim u obliku tablica teško je razumjeti što podaci predstavljaju, kako su organizirani i kako se mijenjaju. Još teže je uvidjeti veze, odnose i uzorke ponašanja podataka. Vizualizacija podataka prikazuje grafički velike količine informacija što ih čini bližima korisnicima i jednostavnijim za razumijevanje. Kada su podaci prikazani grafički, u obliku raznovrsnih grafikona, manjih tablica i grafičkih prikaza tijekom informacija, jednostavnije se uočavaju veze između pojedinih parametara, njihova kretanja i trendovi koje slijede. Na ovaj način mogu se uvidjeti neke veze između parametara koje su drugačijim načinima teško vidljive a značajne su za poslovanje organizacije. Utvrđivanjem veza između podataka, praćenjem kretanja parametara i različitih uzoraka koje prate, organizacije se mogu fokusirati na ona područja koja utječu na ostvarenje njihovih ciljeva. Praćenjem stanja na tim područjima mogu pravovremeno reagirati na promjene i prilagoditi se novonastalom stanju.

Identificiranje trendova u nastajanju. Organizacije vizualizaciju podataka koriste i za otkrivanje trendova, bilo u samoj organizaciji ili na tržištu na kojem posluju. Praćenjem i otkrivanjem trendova organizacije ostaju u tijeku sa promjenama u unutarnjoj i vanjskoj okolini, a upravo to može biti ključan čimbenik prilikom ostvarivanja konkurentske prednosti.

Sa vizualizacijom podataka mogu se uočiti karakteristike u proizvodnom procesu koje utječu na smanjenje kvalitete proizvoda ili usluge. Tada je potrebno djelovati na taj dio proizvodnog procesa kako bi se ispravile nepravilnosti i kupcima isporučio kvalitetan proizvod. Jednako tako mogu se uočiti promjene na tržištu i trendovi koji vladaju među kupcima te utjecati na proizvodnju kako bi se isporučivao proizvod koji će uistinu zadovoljiti ciljnu skupinu kupaca. Uz to mogu se uočiti i novi trendovi koji se pojavljuju među kupcima te reagirati sukladno uočenim promjenama, bilo uvođenjem novog proizvoda ili usluge, promjenom postojećeg ili promjenom ciljne skupine kupaca. U svakom slučaju praćenje trendova u okruženju, njihovo otkrivanje u samom nastanku i reagiranje na te trendove značajan su faktor prilikom osiguravanja i zadržavanja konkurentske prednosti.

Informiranje okoline. Nakon otkrivanja potrebnih informacija, uočavanja trendova i razumijevanja informacija s kojima organizacija raspolaže, potrebno je provesti promjene. Da bi se to ostvarilo potrebno je informirati zaposlenike koji će provoditi nove načine poslovanja, a kako bi oni efikasno mogli odraditi svoj posao trebaju razumjeti o čemu se radi. Korištenje vizualizacije podataka jednostavan je način za postizanje ovog cilja. Zaposlenici će moći razumjeti što se od njih očekuje i zašto se to provodi. Također vizualizacija podataka može se koristiti i za informiranje javnosti, prenošenje poruke poduzeća i iskorištavanje prikupljenih podataka za „pričanje priče“ koja će zainteresirati ciljanu publiku i omogućiti im brzo i lako shvaćanje poruke.²²

3.3. Utjecaj vizualizacije podataka na poslovanje organizacije

Od samih početaka primjene poslovne inteligencije u organizacijama, težilo se osiguravanju načina na koji će organizacije moći jednostavno i praktično raspolagati podacima. Njenom primjenom nastoje se ostvariti tri cilja u organizacijama: otkrivanje, razumijevanje i donošenje informiranih odluka. Prije raširene primjene vizualizacije ovi ciljevi ostvarivali su se uz pomoć stručnjaka (analitičara) koji su mnoštvo prikupljenih podataka obrađivali kompleksnim upitima u SQL bazama te su kreirali izvještaje korištenjem Excel tablica i Microsoft Acces-a ili nekog sličnog programa. Gotove izvještaje su prenosili donositeljima odluka koji su na temelju dobivenih podataka nastojali donijeti kvalitetne odluke za

²² SAS „Data visualization: What it is and why it matters“ https://www.sas.com/en_us/insights/big-data/data-visualization.html (5.8.2017.)

organizaciju. Ove odluke često nisu bile ispravne jer donositelji odluka nisu u potpunosti razumjeli informacije s kojima raspolažu, također, vrlo često odluke su donesene sa zakašnjenjima u odnosu na potrebe i stanje na tržištu. Primjena vizualizacije u organizacijama mijenja ovaj način donošenja odluka. Analitičari danas provode kompleksne analize i optimiziraju sustave za poslovnu inteligenciju kako bi efikasno služili donositeljima odluka koji preko upravljačkih ploča dobivaju najnovije informacije u vizualnom obliku te mogu vršiti dodatne analize nad predstavljenim podacima i donositi kvalitetne odluke u pravom trenutku.

Uvođenje sustava poslovne inteligencije, bez načina prezentacije podataka, ne ostvaruje stvarnu prednost za organizaciju. Kako je prikazano u radu, aktualan i najznačajniji trend u današnje vrijeme je upravo omogućavanje pristupa prikupljenim podacima, dakle vizualizacija. Korištenjem alata za vizualizaciju organizacije su u mogućnosti iskoristiti sav potencijal poslovne inteligencije kako bi svoje poslovanje unaprijedile i optimizirale. Vizualizacija podataka koristi se na različite načine i u različite svrhe u organizacijama, ovisno o njihovim potrebama, ali neovisno o načinu korištenja i ulozi, uvijek organizaciji donosi novčane uštede te bolji položaj na konkurentskom tržištu. U nastavku će se prikazati primjeri nekoliko organizacija koje su uvele razne alate za vizualizaciju te promjene u poslovanju nastale kao posljedica uvođenja tih alata.

3.3.1. Primjer 1. Boeing

Poznati svjetski proizvođač zrakoplova te obrambenih, svemirskih i sigurnosnih sustava učinio je vizualizaciju podataka temeljem svojeg poslovanja 2014. godine, kada su izgradili laboratorij za testiranje, analitiku i razvoj zrakoplova i sustava. Vizualizacija se u organizaciji temelji na geometrijskim i ne geometrijskim podacima. Geometrijski podaci koriste se za izradu zrakoplova, dok se ne geometrijski podaci koriste za sustave, poboljšanje efikasnosti zrakoplova i ispravljanje pogrešaka.

Prilikom razvoja zrakoplova Boeing je trebao optimizirati efikasnost prilikom slijetanja i polijetanja zrakoplova. Kako svaka od ovih radnji generira značajne količine podataka analiziranje kroz uobičajene tablice ne bi bilo moguće. Korištenjem vizualizacije podataka i vizualne analize, stručnjaci su uspjeli iz tog mnoštva generiranih podataka identificirati nepravilnosti koje su dovodile do ne efikasnih polijetanja i slijetanja zrakoplova. Osim u

ovom konkretnom primjeru, Boeing koristi vizualnu analizu i vizualizaciju podataka za praćenje i održavanje sustava, za utvrđivanje i ispravljanje pogrešaka ali i za praćenje odnosa sa klijentima i stanja na tržištu.

Još jedan primjer primjene vizualne analize u Boeingu je prilikom izrade satelita. Prije uvođenja vizualizacije u proces proizvodnje i poslovanje općenito, sateliti su se testirali nakon dovršetka izrade i sastavljanja kompletnog proizvoda, jer nije postojao drugačiji način utvrđivanja i provjere rada satelita. U ovom trenutku proizvod je već bio gotovo u potpunosti dovršen te su sve izmjene i popravci zahtijevali mnogo rada, rastavljanje proizvoda i ponovno sastavljanje nakon popravka dijela koji nije radio. Uvođenjem vizualizacije podataka u poslovanje omogućilo se testiranje proizvoda u različitim uvjetima (scenarijima), na temelju povijesnih podataka i podataka generiranih tijekom izrade samog projekta, čak i prije početka fizičke izrade satelita. Ovakav pristup organizaciji je uštedio mnogo vremena i novca, omogućio kvalitetniju i bržu izradu satelita te je omogućena optimizacija proizvodnje.

Iz Boeing-a kažu kako im korištenje alata za vizualizaciju podataka omogućava testiranje proizvoda ranije u procesu proizvodnje, te brže i kvalitetnije. To dovodi do značajnog smanjenja troškova, manje pogrešaka i lakše mogućnosti uočavanje istih, uz to ostvaruje se i bolja kvaliteta proizvoda. Također omogućava i praćenje rada sustava te brže i lakše ispravljanje eventualnih grešaka nastalih tijekom rada proizvoda. Ova organizacija koristi vizualizaciju za donošenje boljih, informiranih odluka koje im omogućuju bolju prilagodbu tržištu, manje troškove i kvalitetniju isporuku proizvoda.²³

3.3.2. Primjer 2. Barclays

Barclays je poznata europska banka sa dugogodišnjim uspješnim poslovanjem na svjetskom tržištu. Vizualizaciju podataka uveli su 2014. godine, a koriste platformu Tableau, koja predstavlja jedan od vodećih svjetskih alata za vizualizaciju podataka. Primarna upotreba Tableau softvera u banci odnosi se na istraživanje tržišta kupaca. Barclays prikuplja velike količine podataka o svojim klijentima, o stanju na tržištu i potencijalnim korisnicima usluga, a primjena vizualizacije podataka u poslovanju omogućila im je iskorištavanje ovih podataka za

²³ Hawton, J. „Picture-Perfect Data Models Help Build Better Products“, Technology, 2016., <http://www.boeing.com/features/2016/06/casa-06-16.page> (6.8.2017.)

optimizaciju poslovanja, bolje ciljanje klijenata i prilagođavanje ponude na temelju preferencija tržišta.

Prema starijem analitičaru u Barclays Peter Gilks-u, organizacija je uspjela poboljšati svoje odnose s kupcima kroz kontinuirano praćenje podataka o pritužbama klijenata. Praćenjem razloga pritužbi i utvrđivanjem karakteristika klijenata koji su se žalili omogućen je uviđaj u stanje pritužbi na dnevnoj razini. Prikupljanje i analiziranje ovih podataka uz vizualizirani prikaz istih omogućio im je da vide točno u kojim trenucima i iz kojih razloga dolazi do pritužbi klijenata te se napravio i profil klijenata koji se žale. Detaljnijom analizom prikupljenih podataka došlo se do uzroka problema što je banci osiguralo poboljšanje odnosa s klijentima.

U odnosu na način analiziranja podataka u Barclays banci prije uvođenja Tableau softvera došlo je do značajne uštede vremena, time i novca. Naime prije korištenja sustava za vizualizaciju podataka u banci, analitičari su podatke analizirali uz pomoć SQL programiranja te Excel tablica i grafova, što je zahtijevalo mnogo vremena, specijaliziranih znanja i dugotrajnih iterativnih procesa kako bi se izradili grafovi i oblikovali podaci koji će menadžerima biti razumljivi i jednostavni za korištenje i donošenje poslovnih odluka. Korištenjem alata za vizualizaciju analitičari jednostavno mogu provoditi složene analize, a preko interaktivnih sučelja informacije se brzo i lako distribuiraju svima u organizaciji kojima su one potrebne. Na ovaj način omogućen je pristup podacima širem spektru korisnika koji sada imaju uvid u aktualne informacije o poduzeću, a po potrebi mogu samostalno provoditi detaljnije analize kako bi bolje razumjeli prezentirane informacije.²⁴

3.3.3. Primjer 3. Wells Fargo

Wells Fargo & Company je internacionalna organizacija koja se bavi bankarskim i financijskim uslugama i posluje sa više od 70 milijuna korisnika na više od 8 700 lokacija. Ova organizacija raspolaže sa nezamislivo velikim količinama podataka koji nisu uopće bili korišteni. Uvođenjem alata za vizualizaciju omogućena je analiza i korištenje ovih podataka kako bi se optimiziralo poslovanje i ostvarili poslovni ciljevi organizacije, smanjili troškovi te

²⁴Tableau „Barclays innovates with customer insight from Teradata & Tableau“

<https://www.tableau.com/solutions/customer/data-access-leads-innovation-across-barclays> (6.8.2017.)

donosile bolje i kvalitetnije poslovne odluke. Wells Fargo & Company prikuplja podatke od 70 milijuna korisnika, bilo malih poduzeća ili velikih finansijskih ustanova. Iskorištavanje ovih podataka za njih je predstavljalo nemogući pothvat koji je trebao okupirati značajne resurse i veliki broj ljudi kako bi se barem dio podataka mogao iskoristiti u poslovne svrhe. Uvođenje alata za vizualizaciju podataka, u ovom slučaju Tableau-a, omogućilo im je brzu analizu podataka i interaktivnu grafičku prezentaciju potrebnih informacija uz upošljavanje tima od tek nekoliko analitičara.

Poseban poduhvat, zbog kojeg se organizacija Wells Fargo & Company odlučila na uvođenje alata za vizualizaciju bio je redizajn njihovog bankovnog portala. Kako bi napravili kvalitetan novi dizajn bile su im potrebne informacije o mišljenjima njihovih klijenata, koje je organizacija prikupila, ali pristup i iskorištavanje tih informacija bio je gotovo nemoguć. Uposlili su veliki broj stručnjaka kako bi uspjeli doći do informacija ali to nije bilo dovoljno brzo ni efikasno. Podaci nisu bili uređeni, bilo je jako teško snaći se u toliko velikoj količini podataka te ih je prvo trebalo sortirati a tek potom analizirati. Tada su voditelji projekta u dogovoru sa menadžerima i direktorima dogovorili prelazak na korištenje alata za vizualizaciju podataka. Uveden je Tableau koji je omogućio timu analitičara da brzo i jednostavno analizira podatke, utvrdi koje informacije su značajne a koje ne te da te informacije distribuira nadležnima. Na ovaj način napravljen je i osmišljen novi portal koji je omogućio organizaciji da klijentima ispriča kvalitetnu priču o kompaniji uz jednostavno korištenje i pristupačnost.

Upotreba alata za vizualizaciju organizaciji Wells Fargo & Company omogućila je upošljavanje malog tima ljudi koji provode efikasne analize te isporuku potrebnih informacija u vrlo kratkom vremenu kako bi se mogle donositi kvalitetne i informirane odluke koje organizaciji štede novac i vrijeme te joj omogućavaju prilagodbu zahtjevima tržišta.²⁵

²⁵ Tableau „Wells Fargo wrangles data from over 70 million customers to redesign customer banking portal“
<https://www.tableau.com/solutions/customer/storytelling-big-data-wells-fargo> (6.8.2017.)

3.3.4. Primjer 4. Swedish Medical Center

Kako bi poboljšali kvalitetu medicinske usluge i uštedjeli novac, Swedish Medical Center odlučio je u poslovanje bolnice uvesti sustav koji će prikupljati, analizirati i prikazivati podatke o pacijentima, pruženim uslugama i aktivnostima koje se u bolnicama provode.

Projekt uvođenja sustava bio iznimno zahtjevan i velik, jer je ovoj organizaciji bio potreban sustav koji će centralizirano prikupljati i analizirati podatke iz svih odjela bolnice te istima isporučivati informacije koje će svim korisnicima biti lako razumljive i dostupne. Prije uvođenja sustava za analitiku i vizualizaciju, podaci su se prikupljali u obliku izvještaja iz pojedinih odjela koji su se potom analizirali, na temelju dobivenih informacija kreirali su se novi izvještaji za svaki odjel zasebno i ponovno distribuirali natrag u odjele. Međutim ovi izvještaji nisu bili lako čitljivi i dosta korisnika ih je ignoriralo ili nije znalo reagirati u skladu s predstavljenim informacijama. Uvođenjem sustava za analizu i vizualizaciju podataka Swedish Medical Center uspio je objediniti sve svoje procese pod jednu platformu, Tableau, koja analizira sve aspekte poslovanja bolnice, od prihoda i kvalitete usluge do informacija o iskustvu pacijenata za vrijeme boravka u bolnici.

Uvođenje alata za vizualizaciju podataka omogućilo je Swedish Medical Center da svi korisnici, neovisno o odjelu, imaju pristup istim, aktualnim podacima, te da svi odjeli koriste isti način izvještavanja i prikupljanja podataka što je osiguralo značajnu uštedu vremena i novca bolnice. Osim donositelja odluka koji upravljaju bolnicom, pristup informacijama imaju i zaposlenici koji sada mogu vidjeti načine evaluacije njihovog rada, mogu uspoređivati svoje rezultate sa svojim kolegama što ih potiče da pružaju bolju uslugu i kvalitetniju medicinsku skrb pacijentima. Omogućena je i gotovo neposredna reakcija na kritike pacijenata kako bi se poboljšalo njihovo iskustvo boravka u bolnici, a profiti su značajno porasli. Uvođenje alata za vizualizaciju bolnici je omogućilo optimizaciju poslovanja, a potreba za jako malim timom analitičara uz kvalitetnije analize i bolje informacije omogućuju donošenje pravovremenih i informiranih poslovnih odluka te usmjeravanje organizacije prema zahtjevima tržišta.²⁶

²⁶Tableau „Swedish Medical shares quality metrics to improve care & save millions“

<https://www.tableau.com/solutions/customer/swedish-medical-center-sharing-improves-caring-and-offers-millions-dollars-worth> (6.8.2017.)

3.3.5. Primjer 5. Seattle Children's hospital

Seattle Children's je dječja bolnica u Seattle-u, posvećena liječenju i eliminaciji dječjih bolesti. U ovoj organizaciji alat za vizualizaciju uveden je kako bi se efikasnije upravljalo lancem nabave te kako bi se pratilo stanje proizvoda na zalihama te isporuka informacija. Naime Seattle Children's bolnica susrela se sa značajnim problemom konstantnih prevelikih narudžbi i velikog broj proizvoda kojima istječe rok trajanja. Prije uvođenja sustava za vizualizaciju, bolnica je imala ERP sustav preko kojeg su se izdavale narudžbe za proizvode i vodila stanje zaliha. Međutim, kako bi se održavalo „realno“ stanje zaliha, zaposlenici, dakle doktori i medicinske sestre, morali su provjeravati i unositi stanje proizvoda na zalihama. Ovdje je postojalo previše mjesta za ljudsku pogrešku, uz to prilikom kreiranja narudžbe za bilo koji novi proizvod, koji ne postoji u ERP sustavu, trebalo je više od jednog sata kako bi se kreirala ta posebna narudžba. Kao posljedica navedenog pojavio se značajan broj hitnih narudžbi proizvoda jer ih je nestalo na zalihama, a nisu na vrijeme naručeni. Nakon uočenih problema promijenili su način korištenja i nadopunjavanja proizvoda, međutim i dalje je postojao značajan problem analize svih podataka, dostupnosti informacija i brzog pristupa potrebnim informacijama.

Uvođenjem alata za vizualizaciju, Tableau u ovom slučaju, osigurao se potreban pristup informacijama, brza i jednostavna analiza prikupljenih podataka te dostupnost potrebnih informacija svima kojima su one potrebne. Sada su osobe koje su odgovorne za narudžbe proizvoda mogle jednostavno vidjeti stanje na zalihama i uspoređivati informacije te vršiti dodatne, jednostavne analize ako je potrebno. Također omogućeno je i predviđanje potencijalne potrošnje proizvoda na temelju povijesnih i aktualnih informacija te je broj hitnih narudžbi značajno smanjen, a broj proizvoda kojima ističe rok trajanja gotovo je jednak nuli. Uvođenje alata za vizualizaciju omogućilo je i uštedu u pogledu odrađenih kliničkih sati u bolnici, te mogućnost upravljanja značajno većim brojem jedinica za čuvanje zaliha. Također, kako zaposlenici manje vremena izdvajaju za praćenju opreme i proizvoda koje koriste, mogu se posvetiti pružanju kvalitetnije i bolje medicinske skrbi te imaju više vremena za pacijente.²⁷

²⁷ Tableau „Seattle Children's accesses fast, reliable supply chain data“

<https://www.tableau.com/solutions/customer/seattle-childrens-accesses-fast-reliable-supply-chain-data>

(6.8.2017.)

3.4. Vizualizacija podataka u Hrvatskoj

S porastom korištenja poslovne inteligencije u Hrvatskoj dolazi i do povećane potrebe za vizualizacijom. Danas gotovo nema poduzeća koje ne koristi barem neki oblik vizualizacije podataka u svojem poslovanju. Sve tvrtke, manje i veće zasigurno imaju facebook profile koji im služe za promociju, informiranje kupaca i direktan, manje formalan kontakt sa klijentima. Uz korištenje facebook oglašavanja, bilo plaćenog ili ne, neizostavno se koristi analitika dostupna na facebook stranicama. Manje organizacije zadovoljavaju se sa pred definiranom vizualizacijom koja je sastavni dio facebooka, dok veće organizacije koriste raznovrsne alate za vizualizaciju kako bi analizirale i prezentirale, između ostalih i podatke prikupljene sa facebooka.²⁸

Uz facebook vizualizaciju, velika većina organizacija u Hrvatskoj koristi i Google Adwords za oglašavanje. Ovaj alat povezuje se sa Google Analytics alatom koji analizira prodaju, oglase, prihode i ostale podatke koji se prikupljaju sa Google-a, a rezultate vraća u obliku grafičkih izvještaja koje korisnici mogu sami prilagođavati prema njihovim potrebama. Na ovaj način omogućava se jednostavno praćenje online aktivnosti poduzeća, troškovi i prihodi, stanje promotivnih kampanja te ostali podaci od interesa prikazuju se na jednostavan način, a omogućen je i detaljniji uvid u podatke. Međutim, Google Analytics ne analizira poslovanje cjelokupne organizacije, već samo rezultate oglasa na Google-u, odnosno marketinški aspekt poslovanja. Ovdje nisu uračunati prihodi ostvareni drugim kanalima prodaje, pa je ovaj alat koristan za analizu jednog odjela, ali ne i cjelokupne organizacije.

Velike organizacije u Hrvatskoj, kao što su Ledo, Podravka, Dukat, CEMEX, Croatia osiguranje, Erste banka, PBZ card, Addiko Bank, Konzum, Croatia Airlines, Vip, Hrvatski Telekom i druge, koriste integralna rješenja za analizu i vizualizaciju podataka, poput Tableau, IBM Cognos, Quilk i drugih. Ova rješenja za vizualizaciju podataka prate i analiziraju cjelokupno poslovanje organizacije, od marketinških aktivnosti i prihoda do nabave, stanja na tržištu i stanja unutar organizacije, te isporučuju rezultate u obliku lako čitljivih, grafičkih izvještaja koji su donositeljima odluka dostupni u realnom vremenu. Ove organizacije vizualizaciju podataka koriste kako bi unaprijedile svoje poslovanje i zadržale

²⁸ Kutleša, J. „Facebook Data Analytics“, 2017. <http://blog.inteligencija.com/facebook-data-analytics/> (7.8.2017.)

vodeće pozicije na tržištu. Vizualizacija podataka u Hrvatskim organizacijama sve je češća primjena, zbog infiltracije sve većeg broja stranih organizacija na hrvatsko tržište. Kako bi lokalna poduzeća mogla opstati u konkurenciji sa svjetskim divovima moraju razvijati svoje poslovanje, pratiti stanje na tržištu ali i unutar vlastite organizacije te se na vrijeme prilagođavati promjenama i zahtjevima na tržištima na kojima posluju.

Primjer primjene alata za vizualizaciju podataka u Hrvatskoj je u poslovanju organizacije Kolektiva Web d.o.o., prve hrvatske online zajednice za internet kupovinu. Ova organizacija danas posluje u 6 zemalja i upravo zbog velikog opsega poslovanja koji svakim danom generira sve više podataka, pojavila se potreba za uvođenjem alata za vizualizaciju. Temeljitom analizom poslovanja organizacija je ustanovila potrebu za jednostavnim i snažnim rješenjem koje će pružiti potporu odlučivanju, omogućiti analizu podataka i nadzor poslovanja. Za implementaciju su odabrali alat za vizualizaciju podataka hrvatske proizvodnje, BusinessQ. Odabrani alat, nakon uspješne implementacije, omogućio je organizaciji provođenje kompleksnih i brzih analiza podataka, besprijeckornu vizualizaciju podataka, jednostavno izvještavanje i kontinuirano praćenje ključnih indikatora poslovanja, koje je osiguralo mogućnost optimizacije poslovanja. Pristup izvještajima i dijeljenim interaktivnim korisničkim sučeljima imaju svi korisnici u 6 zemalja što osigurava integriranost izvještaja i jednostavno dijeljenje informacija.

Osim u poduzećima, vizualizacija podataka u Hrvatskoj sve više se primjenjuje i u raznim sektorima i gospodarskim granama. Tako se vizualizacija podataka primjenjuje u forenzičkoj analizi kako bi se mnoštvo podataka prikupljeno forenzičkim postupcima jednostavnije i brže analiziralo. Ovo se primarno odnosi na forenzičku analizu financijskih nepravilnosti organizacija. Nakon prikupljanja podataka provodi se analiza na temelju definiranih parametara, kao i kod poslovanja organizacija, te se rezultati analize prikazuju u obliku grafičkih i lako čitljivih izvještaja iz kojih se jednostavno i brzo može zaključiti postoje li ili ne financijske nepravilnosti.²⁹

Vizualizacija podataka koristi se i u Hrvatskim vodama, kako bi se planiralo upravljanje vodenim područjima te planirala područja poplava i prevencije utjecaja sustava za obranu od

²⁹Beroš, I. „Statističke metode u forenzičkoj analizi“, 2017.

<http://www.poslovnaucinkovitost.eu/kolumne/poslovanje/492-grafovi-u-exceluzasto-slika-vrijedi-vise-od-tisucurijeci-ili-brojki.html> (7.8.2017.)

plava na okoliš. Ovi projekti u Hrvatskoj rade se na temelju GIS-a (geografskog informacijskog sustava) kojim se prikupljaju podaci iz Hrvatskih voda ali drugih povezanih organizacija koje posjeduju informacije značajne za ove projekte. Uz pomoć GIS sustava se analiziraju podaci kako bi se dobile kvalitetne i točne informacije dok se uz pomoć alata vizualizaciju ove informacije prenose korisnicima kojima su potrebne za donošenje odluka i djelovanje na području sprječavanja poplava te planiranja upravljanja vodenim područjima Republike Hrvatske. Alat za vizualizaciju posebno je značajan u novije vrijeme, od pridruženja Hrvatske Europskoj Uniji, zbog mnogobrojnih promjena koje je potrebno provesti te uspostave novog načina planiranja i upravljanja vodenim područjima RH.³⁰

4. Alati za vizualizaciju podataka

Alati za vizualizaciju podataka su softveri, povezani sa skladištima podataka, koji obrađuju velike količine informacija i omogućavaju stvaranje personaliziranih izvještaja na interaktivnim sučeljima, gdje su informacije prikazane u obliku grafova, dijagrama, manjih tabličnih prikaza i slično. Ovakvim prikazom alati za vizualizaciju osiguravaju korisnicima pregledan prikaz velikog broja podataka, lako uočavanje trendova i nepravilnosti, te mogućnost dublje analize stavki koje su korisnicima posebno zanimljive.

Postoji mnoštvo alata za vizualizaciju podataka, od onih besplatnih, koji najčešće imaju dosta ograničenu mogućnost korištenja, do vrlo skupih koji nude mogućnosti brojnih analiza te vođenja, praćenja i planiranja cjelokupnog poslovanja velikih organizacija. Iako su besplatni alati najčešće ograničeni načinima upotrebe i mogućnostima provođenja analiza, danas se može pronaći sve veći broj onih koji nude mnogobrojne značajke koje su dovoljne za poslovanje manjih poduzeća. Međutim, ukoliko organizacija prikuplja velike količine podataka, ima razvijena skladišta podataka i nastoji ostvariti konkurentsku prednost iskorištavanjem tih podataka, bit će joj potreban kvalitetan alat uz pomoć kojeg će moći pratiti, analizirati i detaljno istraživati svoje okruženje, unutarnje i vanjsko. Stoga je za ovakve organizacije optimalno rješenje uvođenje kvalitetnog, za njih prilagođenog alata za vizualizaciju podataka, na temelju kojeg će moći planirati poslovanje poduzeća na strateškoj razini.

³⁰ Grizelj Šimić, V. „GIS i njegova primjena u hidrologiji i suvremenom vodnogospodarskom planiranju“, Hrvatske vode, 2014., V88, str. 119-130, http://www.voda.hr/sites/default/files/pdf_clanka/hv_88_2014_119-130_grizeljsimic.pdf (7.8.2017.)

Uvođenje bilo kojeg alata za vizualizaciju zahtjeva resurse i prilagodbu organizacije, jer je to jedini način da se ovi alati implementiraju brzo i jednostavno te da isporučuju proizvod koji bi trebao i koji se od njega očekuje. Organizacija mora biti spremna na promjene koje mogu uključivati i promjene ili prilagodbe softvera ali i hardvera na kojem su do sada radili. Moraju se uzeti u obzir očekivanja koja se stavljaju pred alat za vizualizaciju, ona možda neće moći u potpunosti biti ostvarena. Za to mogu postojati brojni razlozi, kao što su prevelika očekivanja od alata, ne mogućnost ostvarivanja pojedinih karakteristika zbog manjka podataka ili ne mogućnosti iskorištavanja dijela podataka i slično. Dio podataka moći će biti prikazan na „standardizirani“ način, ali svaka organizacija ima vlastite prioritete i ciljeve koje želi ostvariti korištenjem tog alata za vizualizaciju pa se i interaktivno sučelje mora prilagoditi organizaciji, koliko god je to moguće. Dizajneri interaktivnog sučelja trebaju omogućiti alatu nesmetano obavljanje svih funkcija za koje je predviđen uz isporuku točno onih podataka koji organizaciji trebaju. To zahtjeva individualizirani pristup prilikom implementacije alata za vizualizaciju, ali i promjenu načina razmišljanja ljudi u organizaciji. U konačnici, mora se paziti i na zahtjeve koje postavljaju programeri koji razvijaju i implementiraju alat u organizaciju. Zanemarivanje njihovih kriterija i zahtjeva moglo bi dovesti do nepravilnog rada alata za vizualizaciju.

Alati za vizualizaciju zahtijevaju određene karakteristike softvera i hardvera u organizaciji kako bi mogli nesmetano raditi i isporučivati kvalitetnu informaciju. U prošlosti su alati za vizualizaciju zahtijevali značajne softverske i hardverske kapacitete, međutim danas je napredak tehnologije omogućio razvoj sofisticiranih alata koji se mogu pokretati na prijenosnim računalima i mobilnim telefonima uz izvođenje kvalitetnih i dubinskih analiza.

Hardver. Zahtjevi koje pred hardver postavljaju alati za vizualizaciju, u smislu memorijskog kapaciteta i brzine rada, razlikuju se u ovisnosti o tome koji alat se želi implementirati u organizaciju. Međutim svaki od alata za vizualizaciju ima neke minimalne zahtjeve koji moraju biti ispunjeni za normalno funkcioniranje sustava. Također, ukoliko se žele ostvariti neke od naprednih tehnika vizualizacije, kao što su 3D modeliranje i slično, treba se osigurati adekvatna hardverska podloga koja će omogućiti takve prikaze. U današnje vrijeme prijenosna računala su sve snažnija i imaju sve više prostora za pohranu, a mobilni uređaji su sve napredniji što omogućuje pokretanje zahtjevnih alata za vizualizaciju i provođenje kompleksnih analiza. Upravo iz ovog razloga dolazi do potrebe za prilagodbom alata za

vizualizaciju kako bi mogli funkcionirati na različitim hardverskim platformama uz pružanje jednake, očekivane kvalitete informacija.

Softver. Danas organizacije koriste mnogo aplikacija i sustava u svakodnevnom poslovanju te se alat za vizualizaciju mora moći uklopiti u cjelokupan sustav i način rada organizacije. Dakle, mora omogućiti nesmetan rad svim ostalim aplikacijama koje se koriste u poduzeću uz zadržavanje vlastitih performansi na visokoj razini. Neke od aplikacija morat će se implementirati kroz alat za vizualizaciju što zahtjeva i prilagodbu organizacije, dok će neke druge aplikacije možda morati biti reducirane ili zamijenjene kako bi alat mogao neometano funkcionirati. Također, sam softver alata vizualizaciju mora moći provoditi kompleksne analize uz osiguranje brzog i jednostavnog pristupa podacima.³¹

4.1. Karakteristike alata za vizualizaciju

Svi alati za vizualizaciju imaju jednu, zajedničku svrhu – pružanje kvalitetnog i jednostavnog pregleda mnoštva informacija kako bi se olakšalo donošenje informiranih odluka, planiranje poslovanja i usmjeravanje poduzeća na strateškoj razini. Organizacije od alata za vizualizaciju očekuju prikaz aktualnih informacija koje su im od značaja za poslovanje i mogućnost provođenja detaljnih analiza na jednostavan i brz način u svrhu unaprjeđenja poslovanja i ostvarenja njihove uloge u poduzeću. Kako bi se navedeno ostvarilo postoje neke karakteristike alata za vizualizaciju koje alati trebaju imati. Ove karakteristike značajne su za implementaciju i korištenje u organizacijama, a današnji alati ih uglavnom jako dobro zadovoljavaju.

Kodiranje. Nijedan menadžer ili osoba zadužena za donošenje odluka nije programer ni analitičar, a upravo njima su te informacije najpotrebnije, stoga je značajno da ovi alati omoguće pristup informacijama uz što manje do nimalo kodiranja. Uz to, analitičarima koji provode kompleksne i dubinske analize, te kreiraju grafičke prikaze za menadžere značajno je kada mogu jednostavno mijenjati prikaz iz grafičkog u tekstualni i na taj način ubrzati proces analize podataka ali i kontrolirati svoj rad.

³¹Morgan, J. „Requirements for Visualization Software“ <http://usabilityetc.com/articles/visualisation-software-requirements/> (8.8.2017.)

Grafički prikazi. Od alata za vizualizaciju danas se očekuje da sadrže široki spektar grafova i dijagrama, ne samo statističkih, već i onih kojima će se moći vizualizirati hijerarhije, financijski podaci, geografski podaci i slično. Uz to grafički prikazi moraju biti jednostavni uz pružanje svih potrebnih informacija, a trebaju se moći i mijenjati po potrebi korisnika. Također, od alata se očekuje i da se mogu spremati predlošci kako bi se svi sljedeći izvještaji prikazivali na točno određen način koji korisniku odgovara. Trebali bi imati i mogućnost kratkog pregleda svih grafičkih prikaza i najznačajnijih informacija uz jednostavan i pregledan dizajn.

Analiza. Kako bi korisnici informacija mogli u potpunosti razumjeti informacije s kojima raspolazu mora im se omogućiti i detaljnija analiza prikazanih podataka. Dakle u slučaju uočavanja varijable koja odstupa od standardnih vrijednosti ili uočavanja negativnih trendova, alat za vizualizaciju podataka korisniku mora osigurati detaljnije istraživanje problema. Krajnji korisnik mora biti u mogućnosti detaljno pregledati podatke, filtrirati ih i sortirati prema želji te provesti jednostavnije analize nad njima, a ukoliko se utvrdi potreba za dodatnim analizama, analitičari moraju biti u mogućnosti na jednostavan i brz način provesti dubinske analize nad podacima te složene analitičke procese. Bilo bi pogodno kada bi se uz pomoć alata za vizualizaciju koji se koristi u organizaciji mogle provoditi i ovakve, dubinske i napredne analize. To bi osiguralo integraciju i brzu isporuku informacija korisnicima, a analitičarima omogućilo provođenje brzih ali detaljnih analiza podataka. Alati kao što su Qlik, Tableau, Microsoft Power BI i drugi podržavaju ove značajke i olakšavaju integraciju podataka te dijeljenje informacija unutar poduzeća.

Podaci. Alat za vizualizaciju podataka mora biti u mogućnosti spojiti se na različite izvore podataka kako bi imao pristup svim podacima potrebnim za analizu i vizualizaciju. Ovo označava mogućnost spajanja na razne vrste skladišta podataka te pristup podacima smještenim u različitim sustavima, ovdje spada čak i mogućnost korištenja javnih izvora podataka, dakle spajanje na javne baze podataka koje se nalaze u online okruženju. Ova karakteristika alata za vizualizaciju značajna je zbog toga što različite organizacije pohranjuju podatke na različite načine, a česta je pojava i da organizacije različite podatke pohranjuju na nekoliko lokacija (Hadoop i skladišta podataka, ili slični koncepti).

Uz izvore podataka na koje se mora moći spojiti, po pitanju podataka postoji još jedan zahtjev koje organizacije upućuju prema alatima za vizualizaciju. Mogućnost obrade velike, ali i male

količine podataka. Naime, organizacije prikupljaju velike količine podataka iz svoje unutarnje i vanjske okoline te im je potreban alat za vizualizaciju koji može obraditi i prikazati te velike količine podataka. Uz to postoje i zahtjevi za mogućnošću vizualne obrade manje količine podataka, koja će omogućiti lokalnu obradu na stolnim računalima i prikaz informacija bez potrebe za spajanjem na jaki server ili neko slično okruženje.

Dijeljenje informacija. Zahtjevi organizacija od alata za vizualizaciju ne prestaju kod podataka. Alati bi uz sve navedeno trebali imati i mogućnost osiguravanja dijeljenja informacija među korisnicima, distribuciju izvještaja i analiziranih podataka te mogućnost suradničkog rada na analizama. Ove karakteristike osiguravaju jednostavnu i laku distribuciju i prezentaciju informacija te dijeljenje izvještaja među zaposlenicima organizacije. Na ovaj način svi kojima su informacije potrebne mogu imati pristup vizualnim i razumljivim prikazima, a analitičari mogu surađivati za vrijeme provođenja kompleksnih analiza podataka.³²

4.1.1. Što korisnici očekuju od alata za vizualizaciju?

Osim navedenih tehničkih zahtjeva koje alati za vizualizaciju danas trebaju zadovoljavati, postoji još nekoliko zahtjeva s korisničke strane čije ostvarenje je potrebno kako bi alat ostvario svoju namjenu u organizaciji. Prethodno navedeni zahtjevi odnose se na karakteristike koje alat treba imati kako bi se implementirao u organizaciju i ispunio ulogu koja se od njega očekuje, odnosno unaprijedio sveukupno poslovanje organizacije. Dok se sljedeći zahtjevi odnose na mogućnosti analize i interaktivne vizualizacije koju od alata očekuju korisnici, donositelji odluka, kako bi mogli iskoristiti prikupljene podatke, njima upravljati te na temelju njih donosi odluke.

Novi korisnik trebao bi biti u mogućnosti pregledati podatke i izvući potrebne zaključke o trendovima, distribucijama, nepravilnostima i vezama između podataka. Podaci moraju biti prikazani u stvarnom vremenu i predstavljati trenutno stanje u organizaciji, a korisnici moraju biti u mogućnosti provoditi analize nad podacima, bez prethodnih znanja o analitici, načinu rada sustava i statistici koja se koristi za dobivanje informacija. Dakle, interaktivna

³² Lorica, B. „11 essential features that visual analysis tools should have“ <https://www.oreilly.com/ideas/11-essential-features-that-visual-analysis-tools-should-have> (9.8.2017.)

vizualizacija i vizualna analiza moraju biti intuitivni i jednostavni za korištenje kako bi ih i korisnici koji nikada prije nisu bili u kontaktu sa tim alatom za vizualizaciju mogli koristiti. Ovakav pristup potreban je kako se donositelji odluka ne bi morali oslanjati na analitičare za pojašnjenje pojedinih statističkih podataka i detaljnije analize parametara koji su se pokazali značajnima, u svrhu bržeg i efikasnijeg donošenja informiranih odluka koje će organizaciji osigurati napredak.

Alat za vizualizaciju mora omogućiti praćenje procesa, prikazanog na jednostavan, vizualan način, uz korištenje boja i simbola koji će jednako biti razumljivi i analitičarima i menadžerima. Mora se osigurati jednostavno postavljanje pravila kako bi se pratilo ostvarenje KPI-jeva (*eng. Key Performance Indicators*). Na ovaj način pratit će se procesi u organizaciji i vizualno prikazivati stanje tih procesa korištenjem karakterističnih i svima razumljivih simbola i boja. Ovakva vizualizacija procesa osigurava menadžerima da u stvarnom vremenu, na temelju trenutnih podataka imaju brz i jednostavan uvid u procese, probleme koji nastaju i načine na koje se rješavaju, što omogućuje optimizaciju procesa, kvalitetniju i bržu isporuku te uštede.

Prikazani podaci moraju pričati priču kako bi korisnici na jednostavan i brz način mogli povezati sve prikazane informacije o poslovanju i performansama sa poduzećem, troškovima i ostalim karakteristikama. Povezivanjem informacija u jednu smislenu cjelinu, kojom se može upravljati kako bi se informacije sagledale iz različitih perspektiva i u različitim kontekstima, omogućava se razumijevanje velike količine podataka na vrlo jednostavan i intuitivan način. Nakon otkrivanja zanimljivih uzoraka ili nekarakterističnih odstupanja ti podaci se mogu detaljnije istražiti kako bi se dobio bolji uvid u stanje te utvrdio razlog nepravilnosti. Korisnici moraju moći odmah, na prvi pogled biti u mogućnosti uočiti trendove i nepravilnosti među prikazanim informacijama, a na temelju detaljnije analize i interakcije sa grafičkim sučeljem treba biti u mogućnosti utvrditi razloge i uzroke trendova te uočiti njihov utjecaj na cjelokupno poslovanje organizacije.

Potreba za prediktivnom analizom u današnjim poduzećima sve je veća. Želja da se predvide mogući scenariji uzrokovani različitim odlukama i postupcima značajna je posebice kod velikih i brzo rastućih organizacija pa se i od alata za vizualizaciju traži mogućnost prediktivne analize. Međutim, današnji alati za vizualizaciju najčešće prediktivnu analizu izbjegavaju korištenjem preskriptivne analize, odnosno iniciranjem promjena u organizaciji

kako bi se optimiziralo poslovanje i osigurala konkurentsku prednost organizacije u budućnosti isporukom kvalitetnijeg proizvoda ili usluge uz niže troškove. U svrhu optimizacije poslovanja potiče se promjena načina poslovanja i izmjena načina korištenja sredstava u organizaciji, na temelju podataka i informacija koje organizacija posjeduje te algoritama koji na vizualan način prikazuju različite scenarije provođenja predloženih promjena.³³

4.2. Najpoznatiji svjetski alati za vizualizaciju podataka

Postoji dosta alata za vizualizaciju podataka u svijetu i svi su kreirani s namjenom što jednostavnijeg, vizualnog prikaza podataka koji će biti razumljiv svim korisnicima. Svaka organizacija bira alat koji će implementirati u svoje poslovanje na temelju identificiranih potreba i podataka s kojima raspolažu. Ne može se očekivati da će organizacije sa potpuno različitim načinom poslovanja i proizvodnim pogonom ili pružatelji usluga imati jednake potrebe i želje da će raspolagati sa jednakim resursima i podacima. Manje organizacije će zasigurno tražiti optimalno rješenje koje će im omogućiti stjecanje i zadržavanje bolje pozicije na tržištu, dok će velike organizacije tražiti rješenje koje će im omogućiti upravljanje cjelokupnim poslovanjem, optimizaciju velikog broja procesa, iskorištavanje mnoštva prikupljenih podataka te bolju kontrolu nad organizacijom.

Među mnogobrojnim alatima koji se nalaze na tržištu izdvojeni su samo oni za koje su istraživanja pokazala da se najčešće implementiraju u organizacije, a pokazali su se zanimljivima na Gartnerovom magičnom kvadrantu za 2017. godinu. Naravno, za detaljniju obradu odabrani su tržišni predvodnici Tableau, Microsoft i Qlik, zatim vizionari SAP i IBM, te Niche igrači Oracle i Pentaho. U odnosu na 2016. godinu može se zaključiti da su Microsoft i Tableau poboljšali svoje poslovanje, bolje se prilagodili potrebama i željama kupaca te si osigurali bolju poziciju u Gartnerovom kvadrantu, dok je Qlik blago nazadovao u odnosu na prošlu godinu. SAP je zadržao otprilike jednaku poziciju dok je IBM malo napredovao u mogućnosti izvršenja. Oracle u 2016. godini uopće nije bio uvršten u Gartnerov magični kvadrant dok je ove godine promijenio svoju ponudu i prilagodio je potražnji na

³³Kerschberg, B. „Five Key Properties of Interactive Data Visualization“

<https://www.forbes.com/sites/benkerschberg/2014/04/30/five-key-properties-of-interactive-data-visualization/#118bef98589e> (9.8.2017.)

tržištu te je uvršten kao značajan Niche igrač. Pentaho je značajno pao u odnosu na 2016. godinu kada je svrstan u skupinu vizionara sa dosta visokom mogućnošću izvršavanja, dok je ove godine u samom dnu Niche igrača.³⁴



Slika 4. Gartner magic quadrant for business intelligence 2017.

Izvor: <http://optimalbi.com/blog/2017/02/17/gartner-magic-quadrant-for-business-intelligence-2017-cloud-is-coming-slowly/>

³⁴ Gibson, S. „GARTNER MAGIC QUADRANT FOR BUSINESS INTELLIGENCE 2017 – CLOUD IS COMING (SLOWLY)“, <http://optimalbi.com/blog/2017/02/17/gartner-magic-quadrant-for-business-intelligence-2017-cloud-is-coming-slowly/> (10.8.2017.)

4.2.1. Microsoft

Microsoft je jedan od tri predvodnika na tržištu alata za poslovnu inteligenciju i vizualizaciju podataka. U odnosu na 2016. godinu Microsoft je svoju poziciju na tržištu poboljšao i učvrstio uz prilagodbu svog poslovanja i alata kako bi što bolje odgovarao korisnicima. Razvojem i unaprjeđivanjem alata Power BI, Microsoft si je osigurao vodeću poziciju na tržištu i desetu godinu za redom. Trendovi poslovne inteligencije i vizualizacije podataka za 2017. godinu već su prikazani kroz ovaj rad, a Microsoft ih je ovim alatom uspio pratiti i svojim korisnicima osigurati točno ono što žele i trebaju za jednostavno i kvalitetno upravljanje podacima.

Microsoft Power BI je alat za analitiku i vizualizaciju koji omogućava pristup podacima svima kojima su one potrebne u organizaciji. Ovaj sveobuhvatan alat može se povezati na mnogobrojne izvore podataka, pojednostavniti pripremu podataka za analizu te provoditi brze ad hoc analize, uz izvještavanje u jednostavnom i personaliziranom vizualnom obliku. Podatke za analize može prikupljati iz Excel tablica, izvora podataka u operativnom poslovanju, iz oblaka ili skladišta podataka, stoga je pogodan za organizacije koje imaju velike količine podataka pohranjene na različitim mjestima.

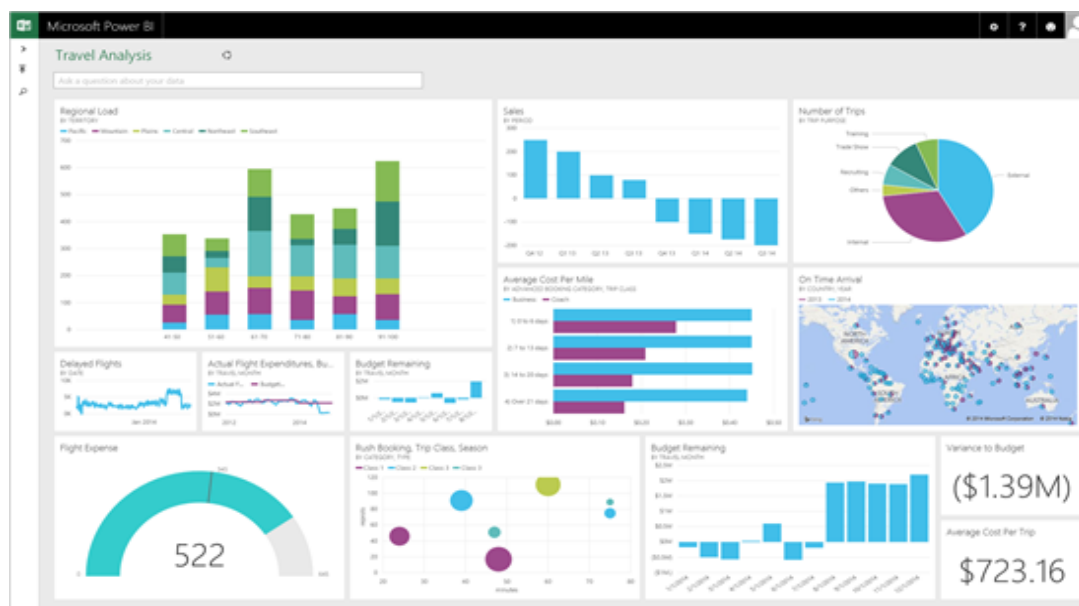
Personaliziranim izvještajima se može pristupiti sa različitih sučelja kao što su mobilni telefoni, prijenosna računala ili tableti. Pomoću ovih izvještaja u svakom trenutku se može pristupiti aktualnim i bitnim podacima neovisno o tome gdje se korisnik nalazi. Izvještaj može biti prikazan u obliku jedne vizualizacije ili više različitih vizualnih prikaza na jednoj stranici te se može sastojati od nekoliko stranica. Slika 5 prikazuje identičan izvještaj na različitim uređajima. Može se vidjeti da ovisno o korištenom uređaju prikazuju se isti podaci ali na različite načine.



Slika 5. Microsoft Power BI izvještaj na različitim uređajima

Izvor: <https://powerbi.microsoft.com/en-us/blog/new-power-bi-features-available-for-preview/>

Ukoliko se žele provoditi analize nad podacima, istražiti pojedini zanimljivi trendovi ili odstupanja i nepravilnosti uočene na vizualnom prikazu koristi se interaktivno sučelje (*eng. Dashboard*). Ovdje se mogu pregledavati izvještaji, vršiti analize i u trenutku pregledavati razni grafički prikazi podataka. Interaktivna sučelja omogućavaju i kontinuirano praćenje stanja u organizaciji preko vizualnih elemenata koji se na njima mogu postaviti. Interaktivno sučelje Microsoft Power BI alata pruža donositeljima odluka mogućnost rada sa podacima i praćenje promjena unutar organizacije te distribuciju izvještaja svima kome su je potreban uvid u podatke. Slika 6 prikazuje izgled interaktivnog sučelja Microsoft Power BI alata za vizualizaciju podataka.



Slika 6. Microsoft Power BI dashboard

Izvor: <https://powerbi.microsoft.com/en-us/blog/new-power-bi-features-available-for-preview/>

Microsoft Power BI alat prilagođen je potrebama svih korisnika, od informatičke službe i analitičara do menadžera i zaposlenika. Ovaj alat za analizu i vizualizaciju podataka korisnicima omogućava jednostavan prikaz analiziranih podataka, mogućnost dodatnog istraživanja tih podataka te distribuciju podataka svim korisnicima kojima su oni potrebni bez narušavanja sigurnosti sustava. Uz pomoć jednostavnih i interaktivnih sučelja Microsoft Power BI osigurao je jednostavnost upotrebe te mogućnost personalizacije sučelja prema korisnikovim željama i potrebama. Sadrži i veliki izbor pred definiranih grafova i dijagrama između kojih korisnici mogu birati za isporuku svojih podataka.³⁵

4.2.2. Tableau

Tableau je drugi od tri vodeća alata za vizualizaciju na tržištu. Gartnerov magični kvadrant pozicionirao ga je kao predvodnika, a u odnosu na poziciju koju je ostvario 2016. godine, Tableau se poboljšao u smislu ispunjenja vizije i mogućnosti izvedbe svojih proizvoda. Međutim, u odnosu na rast koji je ostvario Microsoft, Tableau je ipak ostvario malo lošiji rezultat.

Tableau je jedan od najpoznatijih i najkorištenijih svjetskih alata za vizualizaciju podataka, a sastoji se od nekoliko proizvoda koji se nadopunjuju u stvaranju izvanrednog korisničkog iskustva prilikom obrade, analize, prikaza i dijeljenja podataka. Tableau Desktop je PC inačica na kojoj se obavlja najveći dio aktivnosti, od spajanja na podatke i analiza do izrade izvještaja i prilagodbe interaktivnog sučelja. Podaci se nakon analiza i obrada spremaju na Tableau Server, koji služi kao repozitorij svih provedenih analiza i interaktivnih sučelja koji se rade na Tableau Desktopu. Uz ove dvije inačice proizvoda Tableau, postoje još i Tableau Online koji je inačica Tableau Servera u oblaku, Tableau Reader, besplatni čitač interaktivnih sučelja Tableau Desktopa pomoću kojeg se omogućava distribucija informacija među zaposlenicima i donositeljima odluka u organizaciji. Tableau Public je posebna, besplatna inačica Tableau softvera, koja se može spajati na razne izvore podataka i omogućava dijeljenje analiza i vizualizacija sa svijetom.

³⁵ Power BI <https://powerbi.microsoft.com/en-us/> (10.8.2017.)

Tableau ima mogućnost spajanja na gotovo sve izvore podataka od Excel tablica do raznih SQL relacijskih baza i izvora velikih podataka, a ukoliko organizacija posjeduje jedan od izvora podataka koji nije podržan za direktno spajanje na Tableau, postoji i mogućnost razvoja web connector-a kako bi se baza spojila sa Tableau-om. Stoga su organizacije koje imaju veliki broj podataka u raznim bazama najčešći korisnici Tableau-a. Slika 7 prikazuje povezivanje Tableau Desktop-a sa Tableau Serverom i različitim izvorima podataka. Spajanje na brojne izvore podataka i mogućnost jednostavne analize tih podataka bez potrebe za prethodnom ekstrakcijom podataka značajno je ukoliko se želi provesti brza i efikasna analiza podataka uz kvalitetan vizualni prikaz rezultata na interaktivnom sučelju. Te informacije se potom mogu vrlo brzo i jednostavno distribuirati u obliku izvještaja, svim korisnicima kojima su one potrebne.



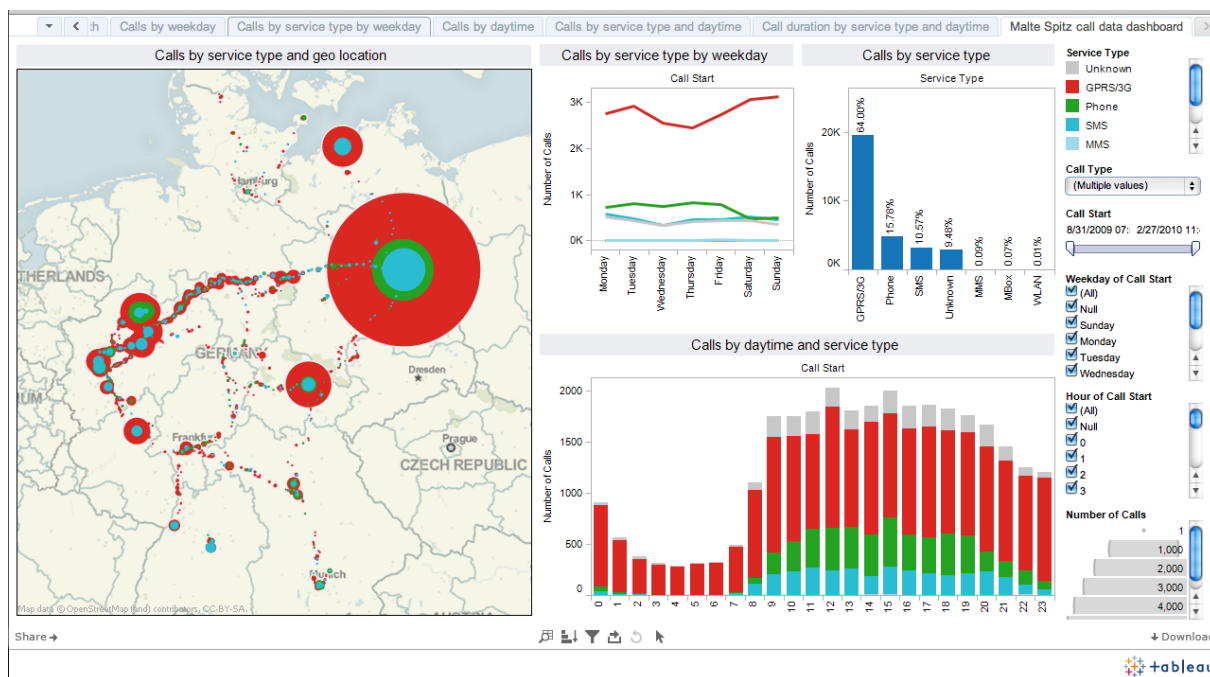
Slika 7. Spajanje Tableau-a na razne izvore podataka

Izvor: <http://blog.inteligencija.com/tableau-analiticki-i-vizualizacijski-alat-nove-generacije/#comment-65>

Tableau omogućava svojim korisnicima iznimno jednostavnu upotrebu uz pomoć interaktivnog sučelja. Naime analize se u Tableau-u vrše uz pomoć jednostavnih drag & drop operacija, bez programiranja, a rezultati se prikazuju unutar samo nekoliko minuta, ovisno o veličini setova podataka koji se obrađuju. Omogućena je personalizirana prilagodba sučelja na kojem se mogu pratiti rezultati u stvarnom vremenu te su omogućena automatska osvježavanja sustava ovisno o potrebama korisnika. Moguće je i postavljanje indikatora te obavještavanje u slučaju da su postavljeni indikatori ostvareni. Korisnici mogu pristupiti podacima sa bilo kojeg uređaja na kojem je postavljen Tableau Reader.

Korištenje Tableau alata za vizualizaciju omogućuje korisnicima provođenje kompleksnih analiza na velikim količinama podataka u jako kratkom vremenu, uz vizualne prikaze i

jednostavno interaktivno sučelje. Ovo sučelje ima mogućnost korištenja neograničenog broja grafičkih elemenata te najširi izbor vizualnih prikaza, od jednostavnih grafova i dijagrama do geo-lokacijskih prikaza i zahtjevnih vizualnih elemenata.³⁶ Slika 8 prikazuje interaktivno sučelje Tableau Desktopa. Na slici se mogu vidjeti raznovrsni grafički prikazi, koji predstavljaju samo neke od prikaza dostupnih u alatu za vizualizaciju Tableau.



Slika 8. Izgled Tableau Dashboard-a

Izvor: <https://www.pinterest.com/pin/388013324116511006/>

4.2.3. Qlik

Posljednji od vodećih alata za vizualizaciju u Gartnerovom kvadrantu je Qlik. Ovaj snažan i intuitivan alat u odnosu na prethodnu godinu ostvario je blagi pad koji Gartner pripisuje uvođenju novog proizvoda na tržište, QlikSense, nakon dugogodišnjeg korištenja QlikView. Međutim, ovaj alat i dalje je kvadrantu predvodnika na tržištu, a to potvrđuju i brojni novi, zadovoljni korisnici.

Osnovna prednost QlikSense alata za vizualizaciju je omogućavanje „self-service“ vizualizacije. Odnosno mogućnost samostalnog stvaranja vizualizacija od strane korisnika, bez potrebnih znanja o analitici i programiranju koje, uz intuitivan dizajn sučelja, omogućuje

³⁶Tableau <https://www.tableau.com/products/desktop> (11.8.2017.)

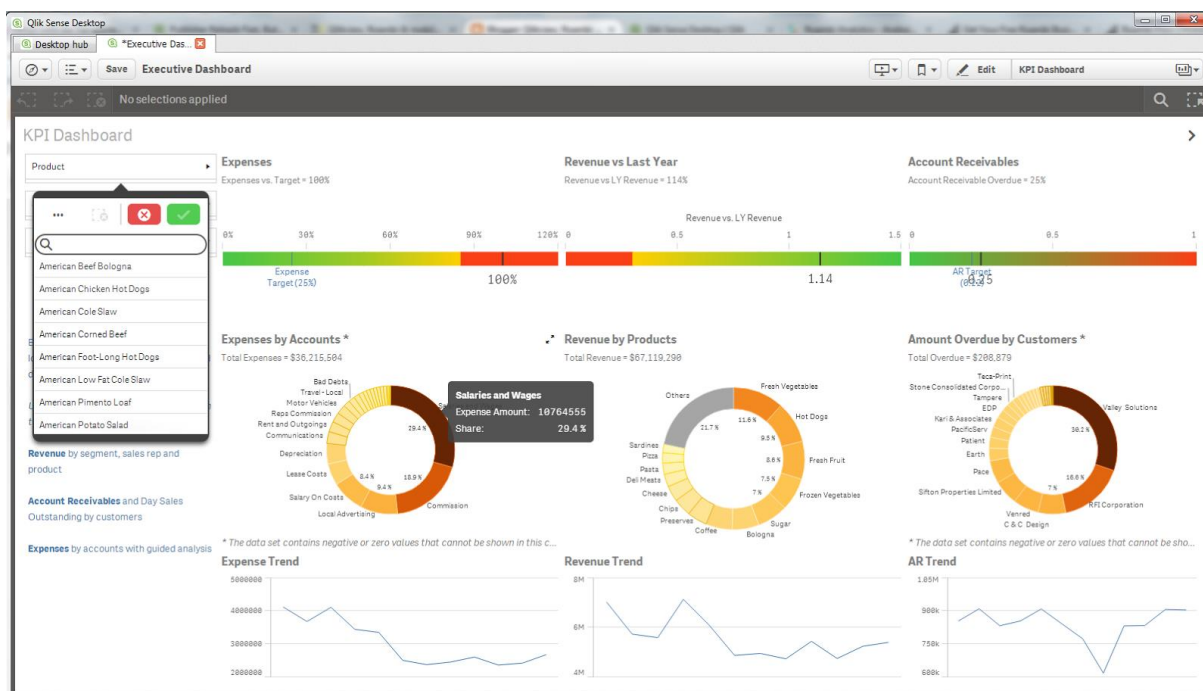
korisnicima jednostavno snalaženje na platformi, brze analize i pregled cjelokupnih informacija organizacije, na jednom mjestu. Qlik nudi mogućnost instalacije besplatne verzije QlikSense Desktop, za individualnu upotrebu. Ovaj alat omogućuje detaljnu analizu i vizualizaciju podataka te se može koristiti na svakom osobnom računalu. Za organizacije Qlik nudi inačicu QlikSense Enterprise koji organizacijama omogućuje vizualizaciju podataka, izradu aplikacija, dijeljenje informacija te suradnički pristup analizama. QlikSense Cloud je online verzija koja omogućava povezivanje na Qlik interaktivno sučelje sa bilo kojeg uređaja, pregledavanje informacija i vršenje analiza podataka. QlikView omogućava pregled izvještaja, praćenje stanja i provođenje dubinskih analiza. Osnovna razlika u odnosu na QlikSense je što ne omogućava intuitivnu vizualnu analizu i stvaranje kreativnih, jednostavnih i korisniku prilagođenih vizualnih prikaza podataka, već koristi standardizirane izvještaje koji imaju ograničenu mogućnost prilagodbe.

Jednostavan dizajn i intuitivno sučelje QlikSense-a omogućavaju korisnicima kreiranje fleksibilnih i interaktivnih vizualizacija koje se mogu detaljnije analizirati te sagledavati uz različite stupnjeve granularnosti. Koristi „pametne“ vizualizacije koje se automatski prilagođavaju postavljenim parametrima i reagiraju na promjene u podacima te se mijenjaju sukladno uočenim promjenama kako bi korisnici uvijek imali pristup najnovijim informacijama i stanjima u organizaciji. QlikSense omogućava jednostavnu integraciju podataka iz različitih izvora i na taj način korisniku pruža potpuni uvid u sve informacije organizacije, kako bi se lakše otkrili uzroci nastanka problema ili trendovi u poslovanju.

QlikSense pogodan je za suradničke analize i omogućava dijeljenje informacija jednostavno i brzo. Također pruža i mogućnost stvaranja dijeljene knjižnice vizualizacija koju stvaraju svi korisnici alata, a modeli podataka, aplikacije, priče i sučelja se mogu koristiti bilo kada uz neograničeni broj ponavljanja, te od strane bilo kojeg korisnika koji ima pristup knjižnici. Ovakva mogućnost dijeljenja informacija i suradničkih analiza iznimno je korisna prilikom obrade velikih količina podataka i provođenja kompleksnih analiza, ali i za informiranje zaposlenika na jednostavan i razumljiv način. Uz to omogućeno je i sagledavanje informacija iz različitih perspektiva te provođenje dubinskih analiza uz jednostavan povratak na pregled podataka na niskoj razini granularnosti.³⁷ Slika 9 predstavlja izgled Qlik interaktivnog sučelja na kojem se vrlo jednostavno, bez poznavanja programiranja i SQL-a jednostavno i brzo

³⁷Qlik <http://www.qlik.com/us/> (11.8.2017.)

moгу vršiti analize uz gotovo trenutane rezultate u jasnom vizualnom obliku koji je korisnik sam odabrao prema vlastitim potrebama i preferencijama.



Slika 9. QlikSense dashboard

Izvor: <http://blog.heldendaten.net/2014/07/summer-of-releases-roambi-for-android.html>

4.2.4. SAP

Alat za vizualizaciju SAP Lumira našao se u samom vrhu vizionara u Gartnetovom magičnom kvadrantu. U odnosu na 2016. godinu obilježio je blagi pad po pitanju mogućnosti izvršenja, ali i dalje je jedan od vodećih alata na tržištu. SAP je na poziciji vizionara već nekoliko godina, a Gartner to pripisuje sporoj prilagodbi novim uvjetima na tržištu, odnosno potrebi za intuitivnom i brzom vizualizacijom te vizualnom analizom. Međutim, ovaj alat još uvijek je značajan igrač na području vizualizacije podataka, a konstantnim se unaprjeđenjima nastoji vratiti na poziciju lidera na tržištu.

SAP Lumira alat je za vizualizaciju koji korisnicima omogućava izradu jednostavnih interaktivnih grafova, mapa i prikaza, te provođenje brze vizualne analize uz pomoć intuitivnih korisničkih sučelja. SAP Lumira može se povezati na veliki broj izvora podataka, a služi i kao alat za vizualizaciju prilikom korištenja SAP BusinessObjects BI. Postoji verzija SAP Lumira Individuals, za individualnu upotrebu. Ova inačica je besplatna i omogućava povezivanje na razne baze podataka i detaljne analize kroz privlačne vizualizacije koje

omogućavaju provođenje analiza bez poznavanja programiranja. SAP Lumira Team inačica je alata za vizualizaciju koja omogućava suradničke analize i dijeljenje informacija s lakoćom. Dok članovi tima mogu pregledavati i dorađivati postojeće analize sigurnost podataka i provedenih analiza je osigurana administratorskim postavkama i ograničenjima korištenja. SAP Lumira Enterprise inačica je alata prilagođena za organizacije. Podržava analizu i vizualizaciju velike količine podataka, vizualna analiza provodi se jednostavno, pomoću interaktivnih sučelja na brz i intuitivan način, te poznavanje programiranja nije potrebno.³⁸

4.2.5. IBM

IBM Watson Analytics alat je za vizualizaciju koji je prema Gartneru pozicioniran u kvadrantu vizionara za 2017. godinu. Ovaj alat je u odnosu na 2016. godinu ostvario bolju poziciju u pogledu mogućnosti izvršenja. Ovaj pomak događa se zbog prilagodbe alata koji se u zadnjih nekoliko godina nalazio u procesu prijelaza prema interaktivnoj vizualizaciji i vizualnoj analizi.

IBM Watson Analytics alat je za vizualizaciju i analizu podataka u organizaciji, a može se jednostavno povezati sa IBM Cognos Analytics. Na ovaj način postiže se potpuna kontrola procesa unutar organizacije uz jednostavnu vizualnu analizu podataka te intuitivno grafičko sučelje. IBM Watson Analytics omogućava provođenje brzih i opsežnih analiza na podacima uz postavljanje jednostavnih upita ili pred definiranih pitanja, a rezultate vraća u lako razumljivom grafičkom obliku. To ga čini jednostavnim za upotrebu gotovo svim korisnicima, te omogućava provođenje analiza i korisnicima koji poznaju samo osnove analitike. Također omogućava i dijeljenje informacija sa timom ili ljudima kojima su one potrebne. Prednost ovog alata za vizualizaciju je što brzo i jednostavno radi sa ne strukturiranim podacima, što značajno ubrzava proces analize.

Ovaj alat za vizualizaciju omogućuje korisniku da izabere jedan od ponuđenih izgleda korisničkog sučelja i prilagodi ga svojim potrebama, te da na jednostavan način prikaže

³⁸ SAP Lumira „Self-service data visualization for everyone“ <https://www.sap.com/products/lumira.html>
(12.8.2017.)

informacije koje su mu potrebne. Ovakav pristup, uz kvalitetnu i brzu analizu, osigurava jednostavno uočavanje trendova u vrlo kratkom vremenskom periodu.³⁹

4.2.6. Oracle

Oracle je ove godine ponovno uvršten u Gartnerov magični kvadrant, na poziciji Niche igrača. U odnosu na 2016. godinu kada nije uopće bio uvršten, ovo je značajan pomak. Iz Oracle-a kažu kako su se potrudili ostvariti bolju komunikaciju s klijentima, novim i postojećim, koji javljaju izvanredne rezultate ostvarene uz korištenje njihovog alata Oracle Data Visualization. Također, Oracle poručuje kako pozicija u Gartnerovom MQ (*eng. Magical Quadrant*) nije odraz stajališta njihovih zadovoljnih klijenata već mišljenja Gartnerovih stručnjaka o mogućnosti izvršenja i ostvarivanju vizije. Ističu kako su njihovi postojeći klijenti zadovoljni rezultatima koje su uz Oracle alat za vizualizaciju ostvarili, te kako su značajno proširili svoju bazu klijenata naporim radom i usavršavanjem svojeg alata.

Oracle Data Visualization alat je za vizualizaciju podataka i vizualnu analizu koji omogućava provođenje kompleksnih analiza na jednostavan i intuitivan način, a rezultati se prikazuju na interaktivnom sučelju koje omogućava jednostavno razumijevanje informacija, sagledavanje željenih podataka uz različite stupnjeve granularnosti i istraživanje uzroka uočenih trendova ili odstupanja. Jednostavno i intuitivno korisničko sučelje (*eng. Dashboard*) omogućava svim korisnicima provođenje analiza, odabir podataka za prikaz te mnogobrojne grafičke prikaze, od grafikona i jednostavnih vizualizacija do geo-mapiranja i stvaranja vizualnih priča koje omogućuju jednostavno razumijevanje cjelokupnog poslovanja i odnosa između procesa u organizaciji. Oracle Data Visualization alat povezuje se na veliki broj izvora podataka te omogućava kombiniranje podataka iz različitih izvora kako bi se provele potpune i detaljne analize te stekao uvid u cjelokupno poslovanje.⁴⁰

³⁹ IBM Watson Analytics <https://www.ibm.com/watson-analytics> (12.8.2017.)

⁴⁰Oracle „Oracle Data Visualization“ <https://www.oracle.com/solutions/business-analytics/data-visualization/capabilities.html#Options> (13.8.2017.)

4.2.7. Pentaho

Pentaho je u Gartnerovom kvadrantu 2016. godine bio na poziciji vizionara, sa dosta visokim stupnjem izvršenja, koji u 2017. godini pada pred samo dno ljestvice. Pogoršala mu se i pozicija na osi ostvarenje vizije. Na ovaj način Pentaho je sa obećavajuće pozicije vizionara pao u samo dno Niche igrača, te će se morati značajno potruditi i prilagoditi svoj alat potražnji na tržištu tijekom ove godine, kako bi se vratio na poziciju vizionara.

Pentaho je svestran alat koji omogućava brojne analize, od jednostavnih do kompleksnih prediktivnih analiza uz vizualno izvještavanje i intuitivno korisničko sučelje koje je dobro prilagođeno i mobilnim uređajima te tabletima. Pentaho osigurava dobru integraciju analitičkih mogućnosti i izvještavanja koja je idealna za osiguravanje dobre komunikacije između analitičara i korisnika informacija. Interaktivna sučelja (eng. *Dashboards*) omogućavaju korisnicima provođenje analiza na jednostavan način, prikaz mnogobrojnih vizualizacija i praćenje tijeka poslovanja.

Pentaho se oslanja na snažne i karakteristične vizualizacije koje korisnicima omogućavaju interakciju s podacima, pregledavanje zanimljivih trendova ili odstupanja na detaljnoj razini, međutim ne nudi mogućnost provođenja detaljnih vizualnih analiza (eng. *Drill Down*) nad prikazanim podacima, već zahtjeva provođenje zasebne detaljne analize i ponovnu isporuku podataka u vizualnom obliku. Ovo je mana zbog koje menadžeri i ostali korisnici koji nemaju znanja o analitici ne mogu samostalno provoditi komplekse analize i detaljno istražiti utjecaje na pojedine trendove ili odstupanja.

S druge strane, Pentaho nudi mogućnost provođenja brzih analiza (ali od strane analitičara), brojne vizualne mogućnosti i prilagodbu intuitivnog korisničkog sučelja prema potrebama i željama korisnika. Veliki raspon mogućnosti za vizualizaciju podataka čini ga pogodnim alatom za sve one koji žele detaljan grafički prikaz različitih vrsta informacija, a mogućnost povezivanja i integriranja brojnih izvora podataka osigurava mogućnost analize, prikaza i praćenja svih podataka u poduzeću te razumijevanje utjecaja pojedinih procesa na druge.⁴¹

⁴¹ Heinze, J. „Pentaho Business Intelligence Review“ <https://www.betterbuys.com/bi/reviews/pentaho-business-intelligence/> (13.8.2017.)

4.3. Usporedba alata za vizualizaciju

Nakon stjecanja kratkog uvida u sve alate koji će se analizirati potrebno ih je usporediti kako bi se vidjelo koji su alati najbolji, zbog čega te koji su nedostaci koje treba ispraviti kako bi alati osigurali organizacijama potpuno ispunjenje potreba i zahtjeva. Za usporedbu alata koristit će se metoda višekriterijalnog odabira, Analitički Hijerarhijski Proces (AHP metoda), kojom će se utvrditi rangiranje alata za vizualizaciju na temelju kriterija koji su se kroz rad pokazali značajnima.

4.3.1. AHP metoda

Za usporedbu prethodno navedenih i kratko opisanih alata za vizualizaciju koristiti će se AHP metoda (*eng. Analytical Hierarchy Process*). Ova metoda jedna je od najpoznatijih za višekriterijalno odlučivanje. Radi se o hijerarhijskoj strukturi, u vrhu koje se nalazi cilj koji se želi postići. U ovom slučaju taj cilj je usporedba alata za vizualizaciju podataka na svjetskom tržištu. Na sljedećoj razini su kriteriji s obzirom na koje se alat bira, zatim se mogu dodati i pod kriteriji, dok se na samom dnu nalaze alternative između kojih se bira. U ovom radu kao alternative su odabrani alati: Tableau, Microsoft, Qlik, SAP, IBM, Oracle i Pentaho. AHP metodom kriterijima se daju različite važnosti usporedbom u parovima. Usporedba se provodi uz pomoć Saaty-eve ljestvice iz koje se dodjeljuju vrijednosti kriterijima koji se uspoređuju. Saaty-eva ljestvica prikaza je tablicom 1 u nastavku. Nakon usporedbi kriterija, na isti način se uspoređuju alati, također u parovima, ali s obzirom na kriterije. Na temelju toga se matematičkim izračunom dolazi do zaključka kvalitete pojedinog alata u odnosu na druge. AHP metoda može otkriti nekonzistentnosti u odlučivanju i osigurati izbjegavanje istih.⁴²

⁴² 123ahp „Metoda izračuna“ <http://www.mojizbormojaodluka.net/OMetodi.aspx> (14.8.2017.)

Tablica 1. Saaty-eva ljestvica

Intenzitet važnosti	Definicija	Objašnjenje
1	Jednako važno	Dva kriterija ili alternative jednako pridonose cilju
3	Umjereno važnije	Na osnovi iskustva i procjena daje se umjerena prednost jednom kriteriju ili alternativu u odnosu na drugi
5	Strogo važnije	Na osnovi iskustva i procjena strogo se favorizira jedan kriterij ili alternativa u odnosu na drugi
7	Vrlo stroga, dokazana važnost	Jedan kriterij ili alternativa izrazito se favorizira u odnosu na drugi, njezina dominacija dokazuje se u praksi
9	Ekstremna važnost	Dokazi na osnovi kojih se favorizira jedan kriterij ili alternativa u odnosu na drugi potvrđeni su s najvećom uvjerljivošću
2, 4, 6, 8	Međuvrijednosti	

Izvor: <http://www.mojizbormojaodluka.net/OMetodi.aspx>

Za usporedbu alata koristiti će se osam kriterija, koji su se kroz rad pokazali značajnima, kako bi alat za vizualizaciju ostvarivao svoju namjenu u organizaciji. Ovi kriteriji izvedeni su iz karakteristika koje organizacije očekuju od alata za vizualizaciju te su rangirani na temelju značaja koji organizacije pridaju svakom od njih.

Kriterij 1 – self service analiza. Alat za vizualizaciju podataka mora omogućiti korisnicima jednostavno provođenje analiza nad podacima, uz korištenje grafičkog sučelja i malo do nimalo kodiranja i SQL upita, kako bi korisnici mogli samostalno provoditi analize, istražiti uzroke pojedinih uočenih trendova i pojava te detaljno pregledati podatke. Mora krajnjim korisnicima omogućiti provođenje drill down i drugih analiza bez pomoći analitičara te osigurati mogućnost brzih i vizualnih povratnih informacija. Također mora omogućiti brzo i jednostavno provođenje kompleksnih analiza te postavljanje ad-hoc upita uz gotovo trenutno vraćanje informacija u vizualnom obliku.

Kriterij 2 – izvori podataka. Većina organizacija podatke prikuplja iz različitih izvora i pohranjuje na više načina. Neki podaci nalaze se u oblaku, neki u Excel tablicama, a neki su u skladištima podataka i slično. Alat za vizualizaciju trebao bi biti u mogućnosti spojiti se na sve izvore podataka te koristiti sve podatke za provođenje brzih i cjelokupnih analiza.

Kriterij 3 – big data. Kako u današnje vrijeme organizacije prikupljaju velike količine podataka potrebno je da alat za vizualizaciju može obraditi i prikazati rezultate za velike količine podataka, ali i za manje setove ukoliko je to organizaciji u danom trenutku potrebno.

Kriterij 4 – dijeljenje informacija. Alat treba obuhvaćati i sustav za dijeljenje informacija, dakle način za slanje izvještaja osobama kojima su oni potrebni, te prikazivanje podataka menadžerima i donositeljima odluka. Prijenos rezultata analize od analitičara do menadžera mora biti jednostavan i brz kako bi osobe kojima su informacije potrebne mogle imati uvid u stvarno stanje u organizaciji.

Kriterij 5 – jednostavnost upotrebe. Alat za vizualizaciju mora osigurati mogućnost jednostavnog korištenja i donositeljima odluka i analitičarima. Treba koristiti prirodni jezik i jednostavne, ne dvosmislene simbole na interaktivnom sučelju. Alat treba biti intuitivan te treba omogućiti korisnicima koji ne poznaju analitiku i programiranje neometano korištenje alata i prikazivanje željenih podataka. Također, treba osigurati korisniku brzo i jednostavno donošenje zaključaka i uočavanje trendova.

Kriterij 6 – praćenje procesa i alerti. Alat treba omogućiti praćenje procesa unutar organizacije, na temelju definiranja KPI-jeva (*eng. Key Performance Indicators*). Vizualizacija procesa i obavještanje korisnika u slučaju ostvarenja zadanih kriterija značajni su prilikom praćenja stanja organizacije i brze reakcije na negativne promjene.

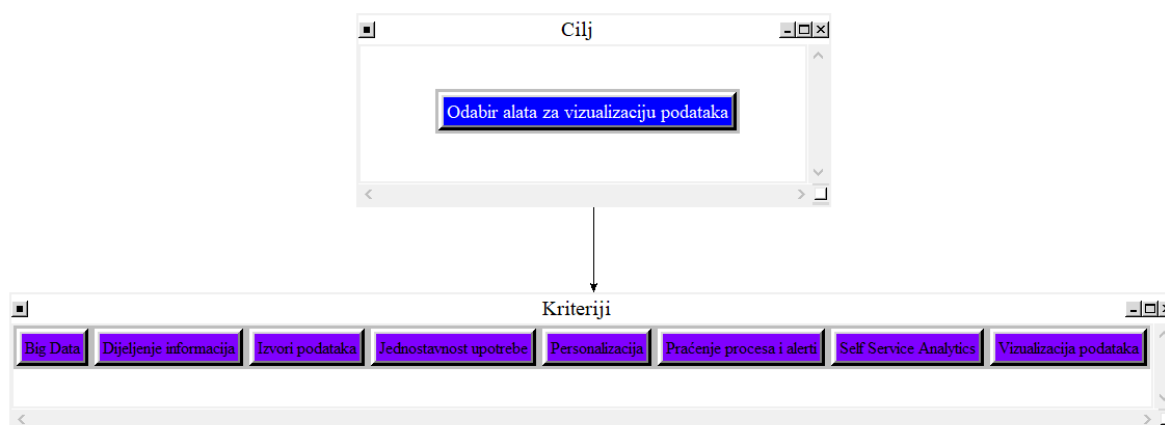
Kriterij 7 – vizualizacija podataka. Alat za vizualizaciju trebao bi osigurati mogućnost korištenja širokog spektra grafičkih prikaza kako bi se svi podaci mogli prikazati na način koji najbolje odgovara korisniku. Grafički prikazi trebali bi biti u mogućnosti prikazati sve vrste podataka, omogućiti kreiranje hijerarhija te prikazivanje geografskih podataka. Korisnik mora na jednostavan način moći odabrati prikaze i uvrstiti podatke za prikaz.

Kriterij 8 – personalizacija. Kako bi alat bio u potpunosti personaliziran treba omogućiti prilagodbu korisničkog sučelja prema korisnikovim željama i potrebama, uz zadržavanje intuitivnosti i interaktivnosti sa podacima. Ova karakteristika značajna je kako bi svaki korisnik mogao prikazati one podatke koji su njemu potrebni za upravljanje organizacijom i koje želi pratiti i analizirati.

Rezultati AHP metode

Za provođenje AHP metode korišten je alat Super Decisions. To je open-source softver koji omogućava provođenje AHP i ANP (*eng. Analytic Network Process*) metode, a najčešće se koristi u akademske svrhe. Super Decisions koristi se za donošenje odluka na temelju mnogostrukih kriterija, zavisnosti i povratnih veza među elementima.⁴³

Nakon analize problema i definiranja kriterija u alatu Super Decisions izrađen je hijerarhijski model problema, na kojem je prikazan cilj koji se želi postići provedbom AHP metode. U ovom slučaju to je izbor alata za vizualizaciju podataka. Ispod cilja u hijerarhijskoj strukturi nalaze se kriteriji za odabir alata, koji su prethodno definirani i objašnjeni. Na temelju ovih kriterija i njihove međusobne važnosti odabrati će se jedan od alata koji bi se u hijerarhijskom modelu nalazili na najnižoj razini hijerarhijske strukture, u klasteru alternative. Međutim kako se u radu provela usporedba korištenjem raiting modela, alternative nisu prikazane u hijerarhijskoj strukturi već u samom raiting modelu. Slika 10. predstavlja izgled hijerarhijskog modela u alatu Super Decisions.



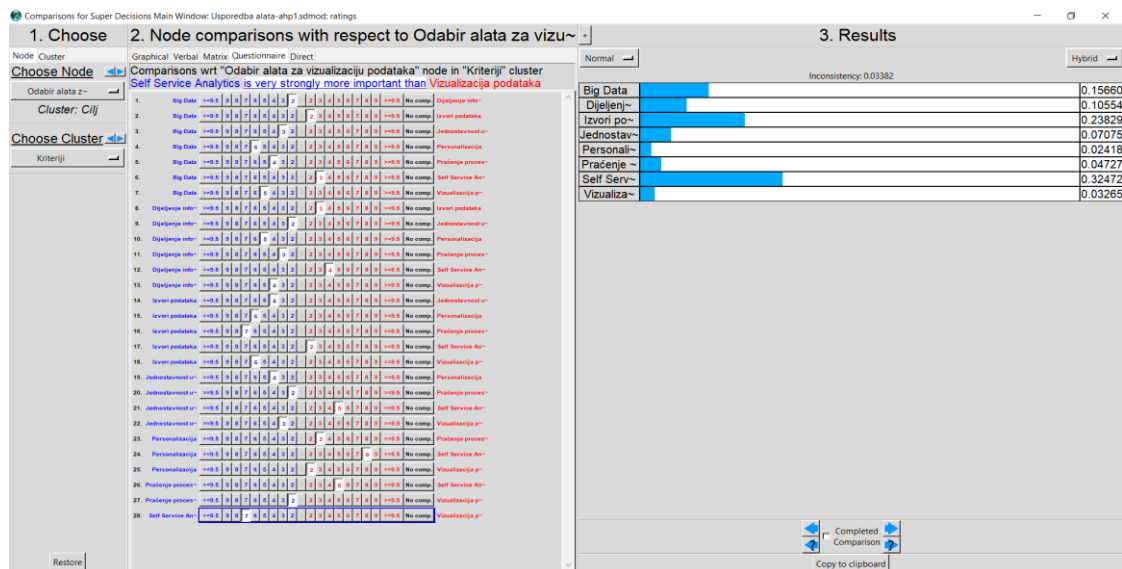
Slika 10. Hijerarhija AHP modela u alatu Super Decisions

Izvor: prikaz autora

Sljedeći korak prilikom provođenja AHP metode je usporedba navedenih kriterija prema Saaty-evoj ljestvici relativne važnosti. Prilikom usporedbe kriterija u parovima istraživač ili donositelj odluke ocjenjuje i vrednuje kriterije na temelju teorijskih saznanja. Prilikom usporedbe korišten je pristup odozgo prema dolje (*eng. Top-down*) što znači da su se prvo uspoređivali kriteriji u odnosu na cilj, a zatim alati u odnosu na svaki od kriterija. U alatu je moguće izabrati usporedbu elemenata opcijom važnost, prioritetnost ili sličnost, a u izradi

⁴³ Super Decisions „About SuperDecisions“ <https://www.superdecisions.com/about/> (14.8.2017.)

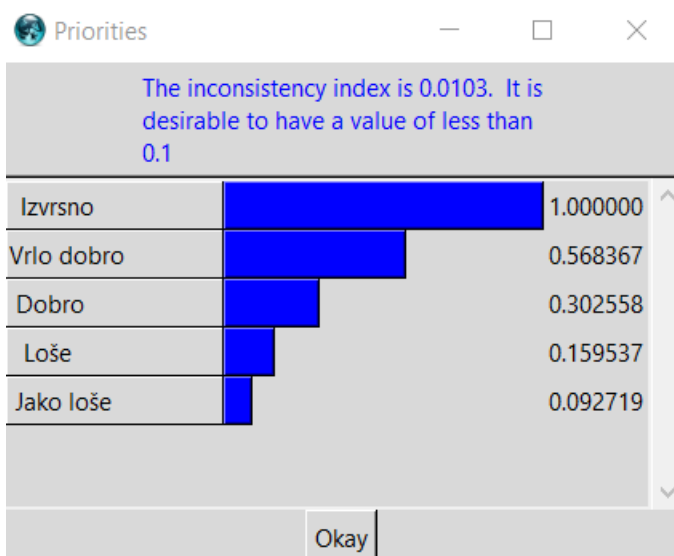
ovog rada usporedba kriterija vršila se usporedbom prema važnosti u odnosu na cilj. Slika 11. prikazuje usporedbu kriterija u alatu Super Decisions. Ocjene su donesene na temelju teorijskih saznanja i iskustava korisnika alata za vizualizaciju, te na temelju online priručnika za odabir alata za vizualizaciju prilikom implementacije u organizacije.



Slika 11. Usporedba kriterija u alatu Super Decisions

Izvor: prikaz autora

Nakon usporedbe kriterija provedena je usporedba alata uz pomoć rating modela u alatu Super Decisions, koji služi za usporedbu većeg broja alternativa i kriterija. Usporedba se provela kreiranjem kategorija Izvrstan, Vrlo dobar, Dobar, Loš i Jako loš, prema kojima su alati rangirani u odnosu na svaki kriterij. Svaka od kategorija uspoređena je prema Saaty-evoj ljestvici kako bi se kreirala važnost svake od kategorija, nakon čega je svakom alatu dodijeljena vrijednost kategorije prema saznanjima prikupljenim opsežnim teorijskim istraživanjem. Na temelju ovih usporedbi donesen je konačni zaključak o odabiru najboljeg alata. Slika 12. predstavlja izgled kategorija kreiranih za svaki kriterij u alatu Super Decisions, te težinske vrijednosti svake od kategorija.



Slika 12. Kategorije kreirane za svaki od kriterija za odabir alata

Izvor: prikaz autora


Po izradi kategorija za svaki od kriterija pristupa se dodjeljivanju ocjena svakom od alata u odnosu na kriterije. Slika 13. prikazuje alate sa dodijeljenim vrijednostima prema kriterijima. Prilikom dodjele ocjene svakom alatu za vizualizaciju, program Super Decisions automatski izračunava položaj alata u odnosu na ostale.

Super Decisions Ratings										
	Priorities	Totals	Big Data 0.156603	Dijeljenje informacija 0.105536	Izvor podataka 0.238294	Jednostavnost up. 0.070750	Personalizacija 0.024181	Praćenje procesa 0.047267	Self Service Anal. 0.324717	Vizualizacija pod. 0.032652
Oracle	0.101253	0.422784	Dobro	Dobro	Dobro	Jednostavno	Vrlo dobro	Dobro	Vrlo dobro	Vrlo dobro
Pentaho	0.080444	0.335896	Jako dobro	Dobro	Jako dobro	Prilagodljivo	Vrlo dobro	Jako loše	Jako loše	Dobro
IBM	0.146316	0.610942	Izvršno	Dobro	Izvršno	Prilagodljivo	Dobro	Izvršno	Dobro	Dobro
SAP	0.115866	0.463800	Izvršno	Dobro	Jako dobro	Prilagodljivo	Dobro	Dobro	Dobro	Vrlo dobro
Qlik	0.163373	0.682166	Jako dobro	Dobro	Dobro	Jako jednostavno	Vrlo dobro	Izvršno	Izvršno	Izvršno
Microsoft	0.171479	0.716010	Izvršno	Izvršno	Jako dobro	Jednostavno	Vrlo dobro	Izvršno	Vrlo dobro	Izvršno
Tableau	0.221269	0.923909	Izvršno	Vrlo dobro	Izvršno	Jednostavno	Izvršno	Izvršno	Izvršno	Izvršno

Slika 13. Tablica Super Decision Ratings


Izvor: prikaz autora

Rezultati provedene metode dobivaju se odabirom opcije sintetiziranja modela kojom se izračunavaju vrijednosti za svaki od alata. Idealizirane vrijednosti dobivaju se dijeljenjem svake normalizirane vrijednosti sa najvećom od njih. Na slici 14. prikazani su rezultati dobiveni alatom Super Decisions. U svrhu jednostavnije usporedbe grafički prikaz rezultata nalazi se na grafikonu 1, izrađen u alatu Excel.



Slika 14. Rezultati AHP metode

Izvor: prikaz autora



Grafikon 1. Prikaz rezultata AHP metode u alatu Excel

Izvor: prikaz autora

Prema rezultatima AHP analize najbolje rezultate ostvario je alat za vizualizaciju Tableau, što je i bilo za očekivati s obzirom na položaj na tržištu te u Gartnerovom kvadrantu. Odmah iza njega su i druga dva predvodnika Microsoftov Power BI i Qlik. Iznenađujuće je da je Microsoftov Power BI bolje pozicioniran od alata Tableau prema Gartnerovom istraživanju, a Tableau je ostvario bolji rezultat. Također, lošije pozicionirani alat u Gartnerovom kvadrantu IBM Watson Analytics, ostvario je bolji rezultat u odnosu na bolje pozicionirani SAP Lumira. Ovakav rezultat postignut je zbog temeljenja Gartnerovog istraživanja na mogućnosti

izvršenja s jedne strane i ispunjenja vizije organizacije s druge, dok se u ovom istraživanju vodilo osnovnim karakteristikama alata koje su utvrđene teorijskim istraživanjem, a u obzir su uzeta i korisnička iskustva.


Rezultati provedene analize značajni su za usporedbu karakteristika alata kako bi svaka organizacija, temeljeno na vlastitim prioritetima i kriterijima mogla izabrati implementirati alat koji će najbolje zadovoljavati njihove potrebe. Svaki od analiziranih alata u ovom radu ima neke prednosti u odnosu na druge te je po pojedinim kriterijima bolji od ostalih. Međutim neki kriteriji značajniji su za vizualizaciju podataka od drugih, a to rangiranje napravljeno je na temelju važnosti koje organizacije najčešće pridaju pojedinim kriterijima. Uzevši u obzir takvu, općenitu važnost kriterija prema kojima su alati analizirani, bolje su rangirani oni alati koji imaju bolje ocjene za kriterije koji su od veće važnosti.

4.3.2. Prednosti i nedostaci alata za vizualizaciju podataka

Na temelju provedene analize podataka mogu se izdvojiti neke od prednosti alata za vizualizaciju podataka koje organizacijama osiguravaju jednostavnije upravljanje, donošenje odluka i praćenje poslovanja. Pozitivne strane alata za vizualizaciju podataka mnogobrojne su i omogućavaju pregled, analizu i iskorištavanje podataka kojima organizacija raspolaže u svrhu boljeg poslovanja, jednostavnije i brže prilagodbe novim uvjetima na tržištu i isporuke kvalitetnijeg i boljeg proizvoda ili usluge uz smanjenje troškova. U ovisnosti o preferencijama organizacije treba se odabrati onaj alat koji će najbolje zadovoljiti njihove potrebe, jer različiti alati imaju naglašene različite karakteristike za postizanje raznovrsnih ciljeva. Upravo iz tog razloga postoje neke karakteristike po kojima se pojedini alati za vizualizaciju ističu u odnosu na druge i koje ih čine prvim izborom za prikupljanje, analizu, distribuciju i prikaz informacija s kojima organizacije raspolažu. Te prednosti istakle su se provedenom analizom, te su izdvojene u nastavku. Ove karakteristike alata za vizualizaciju zaslužne su za njihov uspjeh na tržištu i isporuku kvalitetne usluge organizacijama i pojedincima.

Self service analiza. Alat za vizualizaciju podataka korisnicima omogućava provođenje analiza nad podacima kako bi stekli bolji uvid u prikazane podatke i lakše donijeli kvalitetne odluke. Uz to mora biti jednostavan za korištenje i analitičarima koji provode kompleksne analize nad podacima. Grafikon 2. prikazuje rangiranje alata s obzirom na ovu karakteristiku. Na prikazanom grafikonu može se vidjeti kako su Qlik i Tableau jednaki u odnosu na

jednostavnost samostalnog provođenja analize, a Oracle i Microsoft su odmah nakon njih, dok su SAP, IBM i Pentaho u zaostatku, zbog potrebe da se u njihovim alatima i dalje koriste standardizirani upiti ili korisnici uopće ne mogu provoditi analizu samostalno, kao što je slučaj kod alata Pentaho.



Grafikon 2. Usporedba alata s obzirom na kriterij Self service analiza

Izvor: prikaz autora

Tableau i Qlik svojim korisnicima omogućavaju jednostavno provođenje detaljnih analiza uz korištenje grafičkog sučelja i vizualnih elemenata. Na iznimno jednostavan način korisnici mogu detaljno istražiti pojedine informacije koje ih zanimaju, provesti složene analize, samo uz korištenje vizualnih elemenata na interaktivnom sučelju. Drill down analize, modeli predviđanja i brzi pregledi iz različitih perspektiva samo su dio analiza koje ovi alati omogućuju korisnicima.


Oracle i Microsoft sljedeći su rangirani alati koji korisnicima također omogućavaju provođenje kompleksnih analiza na jednostavan i vizualan način, malo lošiju poziciju u odnosu na prethodne alate imaju zbog malo kompliciranijeg sučelja. Ovakvo sučelje čini ih manje pristupačnima u odnosu na prethodno navedene alate ali zapravo se korisnici vrlo lako i brzo snalaze u alatu. Microsoft koristi dobro poznati dizajn korišten u Microsoft Office alatima, ali u usporedbi sa Qlikom i Tableau-om ipak je složenije i manje intuitivno. Oracle omogućava provođenje velikog broja kompleksnih i zahtjevnih analiza korištenjem vizualnih

elemenata i bez potrebe za dubinskim poznavanjem analitike, čime je osigurano jednostavno provođenje analiza svim korisnicima, od analitičara do menadžera.

SAP i IBM rangirani su nakon Oracle-a i Microsoft-a zbog potrebe za poznavanjem osnova analitike i težeg snalaženja prilikom provođenja analiza. Oni nude mogućnost provođenja kompleksnih analiza i vraćanje rezultata u rekordno brzom vremenu ali je za samo analiziranje podataka potrebno poznavanje osnova analitike i nekih standardiziranih upita. Koriste vizualnu analizu te korisnici mogu vršiti jednostavne analize bez potrebe za postavljanjem upita na bazu podataka, ali ne na razini kao i prethodno opisani alati. Unatoč potrebi za poznavanjem osnova analitike, ovi alati jednostavni su za korištenje i jako su dobro prihvaćeni od strane korisnika jer nude i brojne druge mogućnosti u pogledu mogućnosti analize i praćenja cjelokupnog poslovanja.

Pentaho je posljednji rangirani alat u kategoriji self service analize jer svojim korisnicima ne omogućava provođenje analiza nad podacima, već zahtjeva od analitičara provođenje nove analize s naglaskom na element koji je od interesa korisniku. U ovom alatu korisnik može pregledavati izvještaje, birati koje informacije želi vidjeti i sagledavati ih iz različitih perspektiva ali ne može provoditi dubinske analize i samostalno istražiti razloge odstupanja ili trendova. Dakle Pentaho ne osigurava nikakav oblik self-service poslovne inteligencije.

Izvori podataka. Organizacije prikupljaju podatke iz različitih izvora te ih pohranjuju na različite načine, od pohrane u oblaku i Excel tablica pa do skladišta podataka i relacijskih baza podataka. Zato im je potreban alat za vizualizaciju podataka koji će moći ove podatke objediniti kako bi mogli imati cjelokupan uvid u poslovanje organizacije. Grafikon 3. prikazuje alate za vizualizaciju podataka rangirane u odnosu na zadovoljavanje ovog kriterija. Iako svi analizirani alati imaju mogućnost spajanja na veliki broj izvora podataka ipak postoje razlike u mogućnostima. Tako su vodeću poziciju zauzeli IBM Watson Analytics i Tableau, a nakon njih slijede SAP Lumira, Microsoft Power BI i Pentaho, dok su Oracle i Qlik posljednji rangirani alati.



Grafikon 3. Usporedba alata s obzirom na kriterij izvori podataka


Izvor: prikaz autora

Najbolji rezultat postigli su IBM Watson Analytics i Tableau. I jedan i drugi alat omogućuju spajanje i iskorištavanje podataka iz brojnih izvora te obradu cjelokupnih podataka organizacije brzo i jednostavno. Postoje opcije obrade podataka iz više izvora uz integraciju ali i bez integracije podataka. Tableau ima razvijene i unaprijed ugrađene konektore na gotovo sve izvore podataka koje koriste današnje organizacije, a za one koje nemaju postoji mogućnost naknadnog razvoja konektora kako bi se i ti podaci mogli iskoristiti. IBM omogućava spajanje na mnogobrojne izvore podataka, bilo da se nalaze u oblaku, tablicama, skladištima podataka ili se radi o operativnim podacima iz tekućeg poslovanja. Oba alata omogućavaju obradu svih podataka u vrlo kratkom vremenu kako bi korisnici uvijek imali uvid u trenutno stanje cjelokupnog poslovanja.

SAP Lumira i Pentaho omogućavaju povezivanje sa velikim brojem izvora podataka, te obradu tih podataka uz integraciju svih izvora podataka. Jednostavna integracija omogućava brzo prikupljanje podataka i stvaranje jednog seta podataka koji se može obrađivati u programu. Za razliku od prethodno navedenih alata, koji omogućavaju obradu podataka i bez integracije istih, ovi alati zahtijevaju prethodnu integraciju u jedan set podataka kako bi se mogle provoditi analize. Microsoft Power BI također omogućava povezivanje sa jako velikim brojem izvora podataka, od tablica, preko relacijskih baza sve do skladišta podataka i podataka u oblaku. Povezivanje na izvore podataka je jednostavno i brzo, ali podatke, kao i u prethodnim alatima, treba prvo integrirati kako bi se mogle provoditi analize nad njima.

Oracle omogućuje povezivanje na raznovrsne izvore podataka, ali u odnosu na prethodno navedene alate, znatno je manji broj izvora za povezivanje te je u fokusu povezivanje na Oracle izvore podataka, ali alat se može povezati i na druge izvore. Također omogućena je integracija podataka iz različitih izvora na jednostavan i brz način. Qlik omogućava povezivanje na mnogobrojne izvore podataka te integraciju istih ali izrada konektora za povezivanje na izvore koji nisu standardno podržani nije omogućena od strane Qlika, već treće strane. Ova mogućnost također nije dostupna za standardnu inačicu Qlik Sense. Ovaj alat omogućava brzu i jednostavnu integraciju a potom i obradu podataka, ali za one izvore za koje ima pred definirane konektore.

Big data. Potreba organizacija za obradom velike količine podataka u današnje vrijeme sve je veća, stoga se povećava i potreba za alatima koji omogućavaju obradu velikih količina podataka brzo i efikasno. Grafikon 4. prikazuje usporedbu alata s obzirom na kriterij mogućnosti obrade velikih količina podataka. Kod današnjih alata standard je obrada velikih količina podataka, stoga se uspoređivala brzina analize i mogućnost vizualizacije velikih količina podataka kao i jednostavnost upravljanja podacima.



Grafikon 4. Usporedba alata s obzirom na kriterij obrade velike količine podataka


Izvor: prikaz autora

Alati Tableau, IBM Watson Analytics, SAP Lumira i Microsoft Power BI jednako su dobro rangirani zbog mogućnosti izvrsne obrade velikih količina podataka, provođenja kvalitetnih i opsežnih analiza nad istima koje omogućavaju dubinsko razumijevanje podataka i cjelokupnog poslovanja organizacije. Mnogobrojne vizualizacije dostupne za prikaz ovih podataka dobra su kombinacija sa dubinskim analizama i omogućavaju svim korisnicima

razumijevanje podatka kojima organizacija raspolaže te djelovanje na temelju prezentiranih informacija. Mogućnosti kreiranja priča temeljenih na podacima olakšavaju razumijevanje međusobnih utjecaja čimbenika poslovanja.

Qlik i Pentaho slabije su rangirani u odnosu na prethodne alate za vizualizaciju zbog slabijih mogućnosti obrade velikih količina podataka i ograničenih mogućnosti unosa velikih količina podataka iz izvora koji prikupljaju te podatke. Naime, za razliku od prethodno navedenih alata, Qlik i Pentaho omogućavaju obradu velikih količina podataka u dijelovima, dakle dio podataka se odabere za analizu i oni se obrađuju. Postoji i mogućnost obrade cjelokupnih podataka direktno iz izvora ali provođenje tih analiza je relativno sporo. Oracle je posljednji rangirani alat zbog slabe mogućnosti vizualizacije i obrade velikih količina podataka, naime Oracle ima alate za rad sa velikim podacima, ali Data Visualization nije najbolji izbor za rad na tom području. Naime, ovaj alat omogućava vizualizaciju i analizu velikih količina podataka, ali analize su dosta spore i pogodne za uvođenje u rad sa velikim podacima, ali za zahtjevnije obrade potreban je alat Oracle Big Data Discovery.

Dijeljenje informacija. Ova karakteristika značajna je kako bi informacije dobivene analizom mogle biti dostupne svima kojima su one potrebne za svakodnevno poslovanje i donošenje odluka. Usporedba alata na temelju ovog kriterija prikazana je grafikonom 5. na kojem se može vidjeti značajna razlika između Microsofta i ostalih alata, a razlog tome su različite mogućnosti pristupa informacijama od strane korisnika. Većina alata omogućava pristup analizama i interaktivnim detaljnim prikazima samo ograničenom broju korisnika dok ostali korisnici mogu pregledavati statične izvještaje.



Grafikon 5. Usporedba alata u odnosu na kriterij dijeljenje informacija

Izvor: prikaz autora

Najbolje rangirani alat je Microsoft Power BI, zahvaljujući sustavu online objave izvještaja koji omogućava pristup potrebnim informacijama svim zaposlenicima kojima su one potrebne. Te izvještaje zaposlenici mogu prilagođavati vlastitim potrebama i preferencijama bez utjecaja na originalni objavljeni izvještaj, čime je osigurana sigurnost informacija. Također korisnici imaju pristup detaljnim informacijama i provedenim analizama te sagledavati izvještaj uz različite stupnjeve granularnosti. Ovakav način dijeljenja informacija Microsoft Power BI omogućava bez potrebe za kupnjom individualnih licenci za svakog korisnika. Uz to ovaj alat za vizualizaciju podataka omogućava i jednostavno kreiranje aplikacija za različite uređaje, te se izvještajima i interaktivnim sučeljima može pristupiti i sa mobilnih telefona, prijenosnih računala te tableta.


Odmah nakon Microsofta nalazi se i Tableau, koji također omogućava jednostavno i brzo dijeljenje sadržaja, izvještaja i informacija unutar organizacije. Korištenjem Tableau Servera, na kojem se pohranjuju izvještaji i preko kojeg se distribuiraju, svi korisnici mogu pristupiti ovim informacijama i izvještajima korištenjem besplatne Tableau Reader licence. Nedostatak je što korisnici ovih licenci ne mogu mijenjati izvještaje, sagledavati ih iz drugačijih perspektiva niti imati pristup novim podacima, ukoliko oni postoje. Dakle omogućeno je samo pregledavanje izvršenih analiza i rezultata istih. Kako bi se mogle provoditi analize i kreirati izvještaju potrebna je kupnja licence za Tableau Desktop, koji pruža široke mogućnosti analiziranja podataka, izrade izvještaja i aplikacija za dijeljenje izvještaja preko različitih platformi kao što su tableti i mobilni telefoni.

Ostali alati za vizualizaciju podataka pozicionirani su nakon Tableau-a. SAP i IBM Watson Analytics omogućavaju dijeljenje izvještaja u obliku pdf dokumenta, što osigurava jednostavnu distribuciju informacija, ali ne i interakciju i detaljnija istraživanja prikazanih informacija kao ni uvid u analizu podataka. Ograničenom broju korisnika se može omogućiti pristup, a mogu se ograničiti njihove mogućnosti rada kako bi se očuvao integritet podataka. Oracle također nudi mogućnost izvještavanja užeg kruga korisnika uz interaktivne izvještaje i mogućnosti detaljne analize, ali ostalim korisnicima omogućen je samo pregled analiziranih informacija, odnosno izvještaja u obliku PDF dokumenta ili Power Point prezentacije.

Qlik omogućava distribuciju podataka odabranom broju korisnika koji imaju licencu za QlikSense. Korisnicima je omogućena drill down analiza i pregled izvještaja iz različitih perspektiva ali radi se samo o ograničenom broju korisnika, a ne distribuciji informacija kroz cijelu organizaciju. Qlik može kreirati izvještaje u MS Office alatima te se na taj način

informacije mogu distribuirati kroz organizaciju. Pentaho također ima ograničene mogućnosti izvještavanja i dijeljenja informacija. Iako ima mnogobrojne mogućnosti kreiranja izvještaja i interaktivnih prikaza, dijeljenje informacija uz mogućnost interakcije s podacima ograničeno je na uzak krug korisnika, a podaci se mogu izvesti u Excel, pdf, csv i sličnim formatima kako bi se distribuirali među zaposlenicima.

Jednostavnost upotrebe. Alati za vizualizaciju trebaju biti jednostavni za korištenje svim korisnicima, od menadžera i zaposlenika do analitičara. Analizirani alati za vizualizaciju postigli su dosta varijabilne rezultate na ovom području. Grafikon 6. prikazuje rezultate po alatima za ovu karakteristiku. Iz grafikona može se uočiti da najbolji rezultat ostvaruje Qlik, a prati ga Tableau, Oracle i Microsoft, dok su SAP, IBM i Pentaho lošije rangirani s obzirom na ovaj kriterij.



Grafikon 6. Usporedba alata s obzirom na kriterij jednostavnost upotrebe

Izvor: prikaz autora

Qlik je, sa svojim alatom QlikSense, na ovom području leader na tržištu. Njegovo jednostavno, interaktivno sučelje korisnicima omogućava lako i brzo snalaženje među prikazanim informacijama te jednostavno uočavanje trendova. Ovakvo lako snalaženje među prikazanim informacijama, korisnicima osigurava brzo donošenje odluka i lako uočavanje odstupanja te reakcije na negativne trendove u poslovanju. QlikSense omogućava korisnicima jednostavno kreiranje vlastitih modela podataka te korištenje već stvorenih modela, bilo da su unaprijed integrirani u alat ili su stvoreni od strane nekog od zaposlenika. Interaktivno sučelje sastavljeno je od jednostavnih i lako razumljivih vizualnih prikaza te koristi prirodni jezik, što ga čini dostupnim svim korisnicima. Vrlo je jednostavno kretati se kroz provedene analize i


prikaze podataka, a za kreiranje vlastitih vizualnih prikaza i odabir informacija koje će se prikazivati na sučelju koristi se jednostavna tehnika drag&drop. Postoji mogućnost prikaza velike količine informacija na pregledan i lako razumljiv vizualni način te povezivanje više grafičkih prikaza u jedan kako bi se sagledale informacije iz „ptičje perspektive“.

Tableau, kao jedan od predvodnika na tržištu alata za vizualizaciju podataka, također donosi jednostavno i snažno grafičko sučelje koje je zbog korištenja prirodnog jezika i lako razumljivih simbola vrlo jednostavno za korištenje i izradu vlastitih vizualnih prikaza. Tableau omogućava brzo i lako uočavanje trendova uz pomoć interaktivnog sučelja kojim se osigurava brz i jednostavan prikaz podataka iz poslovanja organizacije, čak i novim korisnicima. Lako kreiranje grafičkih prikaza i usporedba prikazanih informacija omogućavaju jednostavno praćenje stanja u organizaciji te uočavanje odstupanja i brzu reakciju poduzeća. Prilagodba prikaza prema vlastitim željama, na jednostavan i brz način omogućava sagledavanje problema iz različitih perspektiva, a korištenjem jednostavne drag&drop tehnike omogućeno je stvaranje najraznovrsnijih vizualnih prikaza te odabir informacija za prikaz.

Oracle Data Visualization i Microsoft Power BI također su vrlo jednostavni alati za korištenje, te su zaslužili visoku ocjenu za ovu karakteristiku. Interaktivno grafičko sučelje omogućava korisnicima lako i brzo snalaženje, uočavanje trendova te prikaz podataka koje oni žele vidjeti. Jednostavno snalaženje na sučelju olakšava pronalaženje željenog grafičkog prikaza i odabir informacija za prikaz, a lako razumljivi grafički simboli i prirodni jezik ono su što ove alate čini lako dostupnim svim korisnicima. Po kreiranju grafičkih prikaza vrlo je jednostavno uočavati trendove i odstupanja te je lako mijenjati prikaze što ih čini vrlo jednostavnim i intuitivnim alatima koji omogućavaju donositeljima odluka brzo i lako otkrivanje nedostataka u poslovanju te reagiranje na njih. Uz to interaktivno sučelje Microsoft Power BI alata ima karakteristike svima dobro poznatih Microsoft office alata što ga čini lako razumljivim korisnicima.

SAP, IBM i Pentaho imaju interaktivno sučelje, ali je znatno kompleksnije od prethodnih alata i teže se snalaziti. Po pitanju intuitivnosti grafičkog sučelja ovi alati mogu provesti značajna unaprjeđenja. Ova tri alata fokusirala su se na analitiku i integraciju brojnih izvora podataka, ali im vizualizacija podataka i intuitivno korisničko sučelje još uvijek nisu na jako visokoj razini kao što je slučaj kod ostatka analiziranih alata.

Praćenje procesa i alerti. Alat za vizualizaciju podataka organizaciji bi trebao omogućiti praćenje poslovnih procesa i obavještanje prilikom nailaska na neke definirane karakteristike i pokazatelje, KPI (*eng. Key Performance Indicators*). Grafikon 7. prikazuje usporedbu alata u odnosu na ovu mogućnost.



Grafikon 7. Usporedba alata u odnosu na kriterij praćenje procesa i alerti


Izvor: prikaz autora

Alati za vizualizaciju kao što su Tableau, Qlik, Microsoft i IBM omogućavaju definiranje KPI-jeva i praćenje ostvarenja rezultata istih uz obavještanje u stvarnom vremenu ukoliko uočene vrijednosti odstupaju iznad ili ispod postavljenih okvira prihvatljivog kretanja. Takve obavijesti donositeljima odluka omogućavaju reagiranje u najkraćem mogućem roku, bez potrebe za konstantnim provjeravanjem stanja i analiziranjem novo prikupljenih podataka. Ovi alati uz to omogućavaju jednostavno vizualno praćenje procesa i trenutnog stanja u organizaciji, te uočavanje nepravilnosti u radu. Na ovaj način omogućena je optimizacija poslovanja jer se lako i brzo uočavaju nepravilnosti, problemi i zastoji u procesima, te se na jednako tako brzo mogu istražiti uzroci uočenih nepravilnosti kako bi se reagiralo na vrijeme i spriječili daljnji gubici.

Oracle i SAP pružaju mogućnost postavljanja zadanih vrijednosti i izvješćavanje o stanju tih vrijednosti, ali nemaju mogućnost obavješćavanja ukoliko vrijednosti značajno odstupaju od poželjnih. Također ne pružaju ni mogućnost vizualnog praćenja procesa u organizaciji. Pentaho je zadnji alat među analiziranim jer ne nudi mogućnost praćenja željenih karakteristika niti postavljanja poželjnih vrijednosti pojedinih elemenata. Također ne pruža

mogućnost praćenja procesa ni automatsko izvještavanje. Pentaho je po pitanju ovog kriterija jako loš, te postoji mnogo prostora za unaprjeđenje alata.

Vizualizacija podataka. Vrste grafičkih prikaza koje alat za vizualizaciju podataka mora sadržavati su mnogobrojne. Razlog ovome je potreba da se svi podaci i željene informacije prikažu na adekvatan način, koji najbolje odgovara korisniku. Grafikon 8. predstavlja rangiranje alata za vizualizaciju s obzirom na mogućnosti grafičkih prikaza. Svi alati imaju raznovrsne mogućnosti grafičkih prikaza, ali neki ih imaju više a neki manje, pojedini alati čak imaju mogućnost uvrštavanja vlastitih vizualnih prikaza.



Grafikon 8. Usporedba alata u odnosu na kriterij vizualizacije podataka

Izvor: prikaz autora

Najbolje rangirani alati, Tableau, Microsoft i Qlik imaju mogućnost mnogobrojnih grafičkih prikaza te mogućnosti kreiranja vlastitih vizualizacija prema potrebama i željama korisnika. Navedeni alati pružaju brojne mogućnosti, od standardnih grafikona do geo-mapiranja i prikaza podataka na prostornim kartama te toplinskih mapa. Ove raznovrsne vizualizacije i brojni načini prikaza podataka osiguravaju organizacijama prikaz točno onih podataka koje žele vidjeti na točno određeni način koji najbolje odgovara njihovim potrebama.

Oracle i SAP imaju također mnogobrojne vizualne prikaze i veliki izbor grafova, te načina prezentiranja podataka organizacije. Grafički prikazi su malo lošiji od prikaza prethodno navedenih alata koji predvode u ovoj kategoriji, ali su i dalje efikasni, uz mogućnost prikazivanja informacija na raznovrsne načine, prema željama i potrebama korisnika. Pentaho također ima mogućnost prikazivanja velikog broja vizualizacija i raznovrsnih podataka organizacije, ali nema mogućnost stvaranja individualiziranih vizualizacija te nije dostupno

učitavanje dodatnih grafičkih mogućnosti. IBM Watson Analytics snažan je alat za vizualizaciju podataka te ima veliki izbor grafičkih prikaza ali, kao i Pentaho, u usporedbi sa ostalim alatima prezentira znatno manje mogućnosti vizualizacije podataka i grafičkih prikaza.

Personalizacija. Prilagodba alata prema korisnikovim željama i preferencijama jedan je od bitnih kriterija koji omogućuje svim korisnicima jednostavno snalaženje u alatu. Korisnik treba biti u mogućnosti prikazati podatke koje on želi vidjeti i organizirati prikaz na način koji njemu najbolje odgovara. Grafikon 9. prikazuje usporedbu alata u odnosu na ovaj kriterij.



Grafikon 9. Usporedba alata u odnosu na kriterij personalizacija

Izvor: prikaz autora

Najbolje rangirani alat za vizualizaciju podataka je Tableau, koji pruža najšire mogućnosti prilagodbe interaktivnih sučelja korisnicima. Od prilagodbe grafičkih prikaza i informacija koje će se prikazivati na sučelju do promjene tema i boja te izgleda samog sučelja kako bi se korisnik što jednostavnije snalazio u alatu i imao uvid u podatke koji ga zanimaju. Uz broje mogućnosti personalizacije sučelja, Tableau se prilagođava i u odnosu na korisnikov rad, pa se najčešće korišteni izvještaji i analize prikazuju u samom vrhu gdje su lako dostupni, a moguće je i odabrati omiljene aktivnosti. Ovakav pristup korisnicima omogućava jednostavan i brz pristup potrebnim informacijama u svakom trenutku.

Microsoft, Oracle, Qlik i Pentaho lošije su rangirani u odnosu na Tableau zbog slabijih mogućnosti personalizacije i prilagodbe sučelja korisničkim potrebama. Ovi alati podržavaju

izradu personaliziranih grafičkih sučelja i izvještaja koji se mogu prilagoditi svim korisnikovim potrebama i željama, ali izgled naslovne stranice mijenja se nešto teže nego kod vodećeg alata. Uz to nije omogućen prikaz omiljenih aktivnosti nad podacima kao ni omiljenih izvještaja zbog čega je teže pristupiti korištenim analizama i izvještajima, te postoji potreba praćenja pohrane izvještaja koje korisnici kreiraju, preko linkova.

IBM i SAP, iako imaju značajne mogućnosti personalizacije sučelja i izrade analiza i izvještaja po mjeri korisnika, lošije su rangirani zbog teškog prilagođavanja naslovne stranice te malo manjih mogućnosti personalizacije cjelokupnog rada u alatima. Navedeni alati također ne pružaju mogućnost brzog pristupa najčešće korištenim izvještajima i analizama.

4.4. Hrvatski alati za vizualizaciju

Hrvatska je po pitanju alata za vizualizaciju još uvijek u tranzicijskom razdoblju. Dok organizacije sve više uviđaju kako su im ovi alati potrebno za svakodnevno poslovanje, još uvijek postoji značajan broj organizacija, posebice onih manji, koje nisu implementirale nikakva rješenja poslovne inteligencije, a samim tim ni alate za vizualizaciju podataka. Nema mnogo alata za vizualizaciju proizvedenih u Hrvatskoj, ali ovo područje je još u razvoju te se može očekivati značajan uspon u budućnosti. Alati poslovne inteligencije hrvatske proizvodnje, uglavnom su specijalizirana ERP rješenja za praćenje stanja u organizaciji, a prilagođeni su manjim organizacijama i njihovim potrebama, te su mogućnosti vizualizacije podataka kod ovih alata znatno ograničene, a analize podataka najčešće uopće nisu dostupne. Ako se koristi vizualizacija podataka i vizualna analiza, često je specijalizirana za neko određeno područje poslovanja, kao što je slučaj sa alatima za vizualizaciju koji će se detaljnije objasniti u nastavku, CROračun i PROračun, te C2C. S obzirom da su ostali, svjetski alati namijenjeni praćenju sveobuhvatnog stanja u organizaciji i izvan nje, te da omogućavaju analizama i praćenje ukupnog poslovanja organizacije, navedeni alati neće se uspoređivati sa svjetskim divovima na području vizualizacije podataka.

Jedan od hrvatskih alata koji se svakako može uspoređivati sa svjetskim alatima na području vizualizacije podataka jest BusinessQ, kojeg je napravila hrvatska tvrtka sa sjedištem u Zagrebu, Qualia. Ovaj alat za vizualizaciju omogućava analizu i vizualizaciju velikih količina podataka, a prilagođen je kako bi ga mogle koristiti i male i srednje organizacije. Slika 15.

prikazuje usporedbu alata BusinessQ i prethodno analiziranih svjetskih alata za vizualizaciju podataka.

Ratings for Super Decisions Main Window: Usporedba alata-ahp1.sdm: ratings

File Edit View Calculations Help

Super Decisions Ratings										
	Priorities	Totals	Big Data 0.156603	Dijeljenje informacija 0.105536	Izvori podataka 0.238294	Jednostavnost upotrebe 0.070750	Personalizacija 0.024181	Praćenje procesa 0.047267	Self Service Analiza 0.324717	Vizualizacija podataka 0.032652
Oracle	0.092095	0.422784	Dobro	Dobro	Dobro	Jednostavno	Vrlo dobro	Dobro	Vrlo dobro	Vrlo dobro
Pentaho	0.073168	0.335896	Jako dobro	Dobro	Jako dobro	Prihvatljivo	Vrlo dobro	Jako loše	Jako loše	Dobro
IBM	0.133081	0.610942	Izvršno	Dobro	Izvršno	Prihvatljivo	Dobro	Izvršno	Dobro	Dobro
SAP	0.105386	0.483800	Izvršno	Dobro	Jako dobro	Prihvatljivo	Dobro	Dobro	Dobro	Vrlo dobro
Qlik	0.148596	0.682166	Jako dobro	Dobro	Dobro	Jako jednostavno	Vrlo dobro	Izvršno	Izvršno	Izvršno
Microsoft	0.155968	0.716010	Izvršno	Izvršno	Jako dobro	Jednostavno	Vrlo dobro	Izvršno	Vrlo dobro	Izvršno
Tableau	0.201255	0.923909	Izvršno	Vrlo dobro	Izvršno	Jednostavno	Izvršno	Izvršno	Izvršno	Izvršno
BusinessQ	0.090452	0.415241	Dobro	Dobro	Loše	Jednostavno	Dobro	Izvršno	Vrlo dobro	Vrlo dobro

Slika 15. Tablica Super Decision Ratings za usporedbu svjetskih alata i BusinessQ

Izvor: prikaz autora

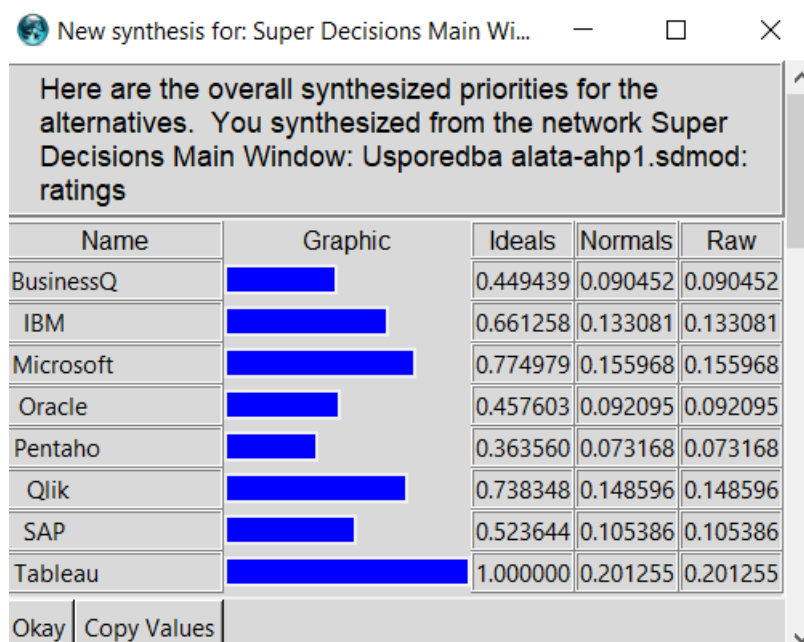
U odnosu na kriterij self service analiza ovaj alat jako je dobar, omogućava provođenje širokog spektra analiza na jednostavan i intuitivan način. Brzo i kvalitetno provođenje opsežnih analiza nad podacima i izvještavanje u vizualnom obliku osnovna su odlika ovog hrvatskog alata.

Uzevši u obzir kriterij izvori podataka, BusinessQ je u odnosu na svjetske alate u blagom zaostatku. Za sada se može povezati na relacijske baze podataka, Excel dokumente, te skladišta podataka, ali svakim danom članovi tima razvijaju nove konektore za povezivanje sa raznim izvorima podataka. S druge strane, ovaj alat omogućava analizu i obradu podataka iz više izvora na jednostavan, vizualan način, što je značajna prednost. Velike količine podataka ne predstavljaju problem za ovaj alat, ali kako je u zaostatku sa povezivanjem na izvore informacija, ti podaci moraju biti u jednom od podržanih izvora kako bi se mogli obrađivati.

S obzirom na kriterij dijeljenje informacija, BusinessQ nudi izvanredno rješenje, naime izvještaji i grafička sučelja mogu se učiniti javnima i dostupna svim zaposlenicima putem web sučelja, samo uz pomoć linka. Međutim, korisnici koji nemaju pristup interaktivnim sučeljima izvještaje i grafičke prikaze mogu samo pregledavati, uz mogućnost pregledavanja iz različitih perspektiva. Lako se izvještajima može pristupiti i na prijenosnom računalu, tabletu te mobilnom uređaju. U odnosu na jednostavnost upotrebe, BusinessQ je u samom vrhu. Ovaj jednostavan i intuitivan alat omogućuje korisnicima provođenje kompleksnih analiza i kreiranje vizualnih prikaza bez potrebe za poznavanjem analitike ili SQL-a.

BusinessQ omogućava praćenje poslovanja uz praćenje KPI te vizualizaciju poslovnih procesa i stanja u organizaciji. Ovo je jedna od njegovih najvećih prednosti. Uz korištenje inovativnog KPI Matrix prikaza za praćenje procesa i stanja ključnih indikatora poslovanja, te izvještavanje ukoliko KPI prelaze dozvoljene granice, praćenje stanja u organizaciji zaista je jednostavno. Brojni vizualni elementi i grafički prikazi omogućavaju kvalitetno prikazivanje svih vrsta podataka, prema korisnikovim željama i potrebama. Također je omogućena prilagodba grafičkih prikaza prema preferencijama korisnika, ali nije dozvoljeno učitavanje dodatnih grafičkih mogućnosti. Personalizacija BusinessQ alata za vizualizaciju je ograničena, korisnici mogu prilagođavati interaktivna vizualna sučelja svojim potrebama, željama i preferencijama ali mijenjanje naslovne stranice i personalizacija analiza nisu jednostavni kao kod nekih svjetskih alata.⁴⁴


Na slici 13. prikazan je rezultat provođenja AHP metode prilikom usporedbe alata BusinessQ i prethodno analiziranih svjetski poznatih alata za vizualizaciju podataka u programu Super Decisions. Na grafikonu 10. prikazani su isti rezultati u alatu Excel kako bi se jednostavnije donio zaključak o pozicioniranju hrvatskog alata u odnosu na svjetske. Iz prikazanog grafikona može se vidjeti kako je alat BusinessQ zapravo postigao dobar rezultat u odnosu na svjetske alate.



Slika 16. Usporedba Hrvatskog alata BusinessQ sa svjetskim alatima

Izvor: prikaz autora

⁴⁴ Qualia – Data Visualization <http://www.qualia.hr/services/data-visualization/> (20.8.2017.)



Grafikon 10. Usporedba alata za vizualizaciju podataka u Excelu

Izvor: prikaz autora

U konačnici, može se zaključiti kako je hrvatski alat BusinessQ jako kvalitetan i dobar alat za vizualizaciju podataka koji može konkurirati na svjetskom tržištu i zadovoljavati sve potrebe svojih korisnika za vizualnim prikazom informacija te praćenjem stanja u organizaciji. Jako je dobar za praćenje procesa i prikaz ključnih indikatora poslovanja, a mnoštvo grafičkih prikaza i jednostavnost provođenja analiza idealni su za poslovne korisnike. Prilagođenost manjim i srednjim organizacijama još je jedna karakteristika koju dosta današnjih alata za vizualizaciju podataka zanemaruje, pa se može reći kako BusinessQ ima jedinstvenu poziciju na tržištu. Postoji još mnogo prostora za napredak, a najznačajniji je po pitanju povezivanja na izvore podataka i obradu velikih količina podataka, u čemu su svjetski alati dosta napredniji. Osim na ovom području, BusinessQ trebao bi unaprijediti mogućnosti dijeljenja informacija te mogućnosti obrade velikih količina podataka kako bi bio zaista prikladan za sve vrste organizacija, od malih do velikih.

Ostali alati za vizualizaciju kreirani u Hrvatskoj uglavnom su specijalizirani za određeno područje poslovanja, te ih se iz tog razloga neće uspoređivati sa svjetskima. Hrvatska organizacija Coin d.o.o kreirala je alate za analizu i vizualizaciju lokalnih proračuna CROračun i PROračun. Navedeni alati služe za interaktivnu vizualizaciju podataka o ostvarenju lokalnih proračuna. Primjenom alata CROračun omogućeno je provođenje višedimenzionalne analize podataka, usporedba lokalnih proračuna svih lokalnih jedinica u RH, te utvrđivanje planiranih i ostvarenih poduhvata financiranih iz proračuna lokalnih

jedinica. CROračun je specijaliziran za usporedbu aktivnosti više lokalnih jedinica, njihovih proračuna i ostvarenih rezultata, dok je PROračun aplikacija otvorena i građanima, kako bi mogli vidjeti planirane i ostvarene rezultate na razini lokalne jedinice i svojim prijedlozima, na temelju analiziranih informacija, pomogli razvoju svojeg grada. Također građani mogu vidjeti na što se planiraju potrošiti novci poreznih obveznika, te na što su zapravo potrošeni u prethodnim razdobljima. Uz pomoć ovih alata omogućeno je praćenje i planiranje proračuna osobama koje su za to zadužene, na razinama koje su pod njihovom ovlasti, uz uvid u stanja proračuna ostalih razina unutar gradske uprave ali i drugih lokalnih jedinica.⁴⁵

C2C alat je također kreiran od strane organizacije Coin d.o.o, dizajniran kako bi stanovništvu dao uvid u stanje pojedinih gradova u kojima žive. Alat pruža mogućnost analiziranja i uvida u informacije iz četiri značajna područja: populacija, turizam, ekonomija i organizacije. Svako od područja može se analizirati prema velikom broju kriterija. Omogućeno je rudarenje podataka, sortiranje, filtriranje, rangiranje te provođenje detaljnih analiza. Za korisnike koji nisu skloni provođenju detaljnih analiza, omogućeno je pregledavanje trenutnog stanja i indikatora odabranih tema. Informacije za analize prikupljaju se iz različitih besplatnih izvora, kako državnih tako i javnih portala, te se koriste i informacije dostupne na tržištu. Korištenjem ovog alata za vizualizaciju podataka građani mogu vidjeti trenutno stanje u njihovom gradu, članovi uprave grada mogu pratiti promjene u različitim područjima, a privatne organizacije mogu vidjeti kakvo je stanje na tržištu i svoj položaj u odnosu na druge organizacije u gradu.⁴⁶

5. Primjena alata za vizualizaciju u Hrvatskoj

Hrvatske organizacije su tek unazad nekoliko godina počele sa značajnijom implementacijom rješenja poslovne inteligencije, stoga je primjena alata za vizualizaciju podataka još uvijek na jako niskoj razini. To se posebice odnosi na svjetske, poznate ali i skupe alate za vizualizaciju podataka. Značajan broj organizacija koristi specijalizirane alate za pojedine odjele u organizaciji, tako se često nailazi na sustave za upravljanje dokumentima, sustave za kredite, sustave za kontrolu proizvodnog procesa i skladišta i slično. Znatno je manja upotreba skupih

⁴⁵Lider.media <https://lider.media/aktualno/biznis-i-politika/hrvatska/croracun-i-proracun-alati-za-vizualizaciju-lokalnih-proracuna/> (21.8.2017.)

⁴⁶DataSimplified „Modern city. Informed citizens.“ <http://www.datasimplified.com/c2c.php> (21.8.2017.)

alata za vizualizaciju analiziranih u prethodnim poglavljima, a najčešće ih primjenjuju velike, multinacionalne organizacije koje imaju svoje podružnice u Hrvatskoj. Od Hrvatskih organizacija ovi alati primjenjuju se u Ledu, Croatia Airlines-u, Plivi, Podravki, Zagrebačkoj banci, Hrvatskom telekomu, Hrvatskoj elektroprivredi, INA-i i sličnim velikim korporacijama koje posluju na razini cijele Hrvatske, Europe ili svijeta.

5.1. Svjetski alati u hrvatskim organizacijama

Kao što je već navedeno, u Hrvatskoj je pojam vizualizacije podataka još uvijek relativno nov termin i postoji značajan broj organizacija koje ne poznaju pojam vizualizacije podataka ili vizualne analize. No svijest o važnosti poslovne inteligencije i vizualizacije podataka u Hrvatskoj konstantno se podiže, čemu svjedoči i značajan porast u potražnji za rješenjima poslovne inteligencije i vizualizacije podataka u posljednjih dvije godine. Također, provodi se i značajan broj seminara, predavanja i edukacija iz područja vizualizacije podataka i vizualne analize, a odazivi su redovito jako visoki. U posljednje vrijeme Hrvatska se istakla kao tržište sa visokim potencijalom za implementaciju svjetskih alata za vizualizaciju, čemu svjedoči i uspjeh tvrtke Adacta koja je 2017. godine proglašena elitnim partnerom za alat Qlik.

„Sve organizacije imaju potrebu za prikladnim izvještavanjem na nekoj razini. Čak i najmanje tvrtke trebaju neki oblik inteligentnih izvještaja, analize podataka ili nadzornih ploča kako bi, primjerice, utvrdili koji se artikli najbolje prodaju i gdje, koja su moguća područja poboljšanja, koji su zaposlenici ispunili osobni KPI ili cilj, koje proizvode ne valja proizvoditi pod nekim uvjetima, a koje treba proizvoditi više i sl.“ Hrvoje Smolić iz tvrtke Qualia.

Hrvatske organizacije koje su implementirale svjetske alate za vizualizaciju podataka, uglavnom su velike tvrtke koje posluju na razini cijele zemlje ili regije, a implementacijom su si osigurale mogućnost rasta i razvoja na tržištu, praćenje poslovnih procesa, optimizaciju poslovanja te brzo i kvalitetno donošenje poslovnih odluka koje osiguravaju prilagodbu promjenama na tržištu. Najčešće su to tvrtke u sektoru telekomunikacija, financija, energetskom sektoru, hotelijerstvu, veleprodaji i maloprodaji te osiguranju i javnom sektoru.

U današnje vrijeme razvoj novih rješenja za vizualizaciju podataka, unaprjeđenje karakteristika i sve veća ponuda alata dovela je do pada cijena, što ih je učinilo dostupnima i organizacijama srednje veličine, koje bi na ovaj način mogle poboljšati svoju poziciju na tržištu, smanjiti troškove i povećati kvalitetu proizvoda ili usluge. Prilagođeni sustavi naplate i mogućnost plaćanja u odnosu na broj licenci implementiranog rješenja značajni su za manje organizacije kojima je na ovaj način omogućen uvid u sve informacije s kojima raspolažu, uz jednostavno provođenje analiza zbog kojeg im nije potrebno zapošljavanje skupih timova analitičara. Međutim, u Hrvatskoj je vizualizacija podataka još uvijek na jako niskoj razini i među velikim organizacijama, a posebice među manjim i srednjim.⁴⁷

Svjetski alati za vizualizaciju podataka, kao što su Tableau, Qlik, Microsoft Power BI, IBM, SAP i Oracle pronašli su put do organizacija u Hrvatskoj, dok istraživanjem nije pronađena niti jedna upotreba alata Pentaho kao osnove za vizualizaciju podataka u organizaciji. Navedeni alati koriste se za izvještavanje velikog broja korisnika, jednostavnije provođenje kompleksnih analiza, praćenje i nadzor poslovanja, bolje i kvalitetnije donošenje odluka, strateško planiranje te kako bi donositelji odluka bolje i brže razumijeli informacije, utjecaje i poveznice između različitih poslovnih procesa u organizaciji. Neke od hrvatskih organizacija koje su implementirale alate za vizualizaciju podataka u svoje poslovanje navedene su u nastavku. Uglavnom su to velike organizacije, ali navedeno je i nekoliko srednjih. Naglasak je stavljen na implementirane alate i mogućnosti koje organizacije otvaraju korištenjem istih.

Zagrebačka banka jedna je od vodećih u Hrvatskoj, a jednako vodstvo očekuje se i po pitanju tehnoloških rješenja koje koristi za praćenje cjelokupnog poslovanja i osiguravanje kvalitete usluge. Kako bi osigurala unaprjeđenje poslovanja i kvalitetniju isporuku usluga Zagrebačka banka angažirala je tvrtku Neos za implementaciju sveobuhvatnog rješenja poslovne inteligencije u poslovanje, uključujući i alat za vizualizaciju podataka. Tako je u organizaciju uz postojeću bazu podataka IBM DB2 implementirana i Oracle Essbase baza podataka, te Oracle Business Intelligence alat uz kojeg i Oracle Data Visualization. Na ovaj način osigurano je moderno i jednostavno izvještavanje, uz kontinuirano praćenje procesa i stanja u organizaciji. Omogućeno je i jednostavno provođenje analiza velikih količina podataka s kojima banka raspolaže, a donositeljima odluka uvid u sve važne informacije o

⁴⁷ Glojnarčić, V. „Tvrtke žele prediktivnu analitiku kao dio standardne ponude BI alata“, BIZdirekt, 2017.

<http://www.mirakul.hr/bizdirekt/tvrtke-zele-prediktivnu-analitiku-dio-standardne-ponude-alata/> (23.8.2017.)

poslovanju. Korištenjem interaktivnih sučelja, putem kojih se na jednostavan način mogu provoditi detaljne analize, osigurana je mogućnost razumijevanja svih prikazanih informacija kao i otkrivanje uzroka nastajanja pojedinih odstupanja ili trendova. Korištenjem interaktivnih izvještaja i korisničkih sučelja pružen je uvid u kompleksne podatke na razumljiv i jednostavan način. Kako bi se maksimalno pojednostavnilo izvještavanje, na interaktivnim sučeljima, korisnicima je omogućen i pristup statičnim izvještajima spremnim za ispis ili distribuciju u obliku Excel dokumenta.⁴⁸

Hrvatska elektroprivreda (HEP) je nacionalna organizacija za proizvodnju i distribuciju električne energije, koja je na tržištu prisutna više od sto godina. U posljednjih nekoliko godina proširila je svoje poslovanje i na distribuciju goriva i termalne energije, čime se značajno proširio opseg poslovanja. Zbog širokog i kompleksnog poslovanja u HEP-u se pojavila potreba za primjenom poslovne inteligencije i vizualizacije podataka. Međutim, kako HEP Grupu čini nekoliko tvrtki bilo je potrebno uvesti kompletno rješenje koje će objединiti sve organizacije i osigurati konzistentnost u provođenju analiza i izvještavanju. To se pokazalo kao jako zahtjevan poduhvat po pitanju utvrđivanja zahtjeva korisnika i zadovoljavanja očekivanja istih. Prvo se proveo pilot projekt kojim se testiralo zadovoljavanje zahtjeva korisnika i valjanost skladišta podataka te sustava poslovne inteligencije i izvještavanja. Nakon uspješno provedenog pilot projekta započelo se sa implementacijom sustava poslovne inteligencije po poslovnim područjima HEP-a. Na ovaj način osigurano je brže i kvalitetnije uvođenje sustava poslovne inteligencije i brz početak rada na novom sustavu. Implementirana je Oracle baza podataka te Oracle Business Intelligence alat za poslovnu inteligenciju, uz kojeg i Oracle Data Visualization alat. Korištenjem navedenih rješenja omogućeno je praćenje cjelokupnog poslovanja po poslovnim područjima, praćenje stanja KPI, provođenje kompleksnih analiza nad prikupljenim podacima i izvještavanje uz interaktivna sučelja. Korištenjem interaktivnih sučelja donositelji odluka stekli su uvid u sve važne poslovne procese i informacije uz mogućnost provođenja detaljnih analiza kako bi bolje razumjeli uzroke nepravilnosti i na njih djelovali, sve u cilju poboljšanja poslovanja.⁴⁹

⁴⁸ Neos.hr „ZABA – BI consulting“ <http://www.neos.hr/about-us/references/?show=zaba-bi-consulting> (23.8.2017.)

⁴⁹ Neos.hr „HEP - Business Intelligence system“ <http://www.neos.hr/about-us/references/?show=hep-bussiness-intelligence-system> (23.8.2017.)

Renault Nissan Hrvatska tvrtka je specijalizirana za uvoz i prodaju automobila marki Renault, Nissan i Dacia. U Hrvatskoj je prisutna već 25 godina, te imaju preko 25 prodajnih mjesta u državi i 64 zaposlene osobe. Prije implementacije alata za vizualizaciju podataka u poduzeću nije postojao jedinstveni način izvještavanja kao ni automatsko prikupljanje podataka. A kako je Renault Nissan Hrvatska dio globalne korporacije Renault, težilo se uspostaviti rješenja koje će omogućiti i jednostavnu komunikaciju sa svjetskim predstavnicima. Zbog toga je u ovu organizaciju uveden alat Qlik, inačica QlikView. Uvođenjem ovog alata za vizualizaciju podataka omogućeno je automatizirano prikupljanje podataka i izrada standardiziranih obrazaca za unos i obradu podataka kako bi se postigla konzistentnost i jedinstveni način izvještavanja svih poslovnica u Hrvatskoj, uz osiguranje kompatibilnosti sa alatima i izvještajima koje koristi svjetska Renault Nissan grupa. Glavni problem predstavljen pred implementaciju alata Qlik bio je analiza jedinstvenih pokazatelja uspješnosti svakog od prodavatelja i stvaranje podataka koji se mogu uspoređivati. To je riješeno uspostavom standardiziranih obrazaca uz pomoć kojih se podaci o uspješnosti prodaje danas prikupljaju. Za implementaciju kompletnog rješenja u sva prodajna mjesta u Hrvatskoj bilo je potrebno otprilike tri mjeseca, a tvrtka Adacta iskoristila je svoje iskustvo i znanje kako bi pomogla u reorganizaciji poslovnih procesa u svrhu unaprjeđenja cjelokupnog poslovanja i olakšanog korištenja alata Qlik. Uspostavom ovog alata za vizualizaciju Renault Nissan Hrvatska osigurao si je mogućnost brze reakcije na promjene u okruženju, standardiziranost izvještaja i vizualizaciju informacija cjelokupnog poslovanja. U sljedećim koracima planira se i prelazak na tehnologije koje će im omogućiti vizualnu analizu i bolje predviđanje tržišne situacije kako bi pravovremeno reagirali na promjene i osigurali kvalitetnije poslovanje.⁵⁰

“Prilikom uvođenja shvatili smo da različite direkcije prikazuju podatke na različite načine, da ukoliko netko nije specijalist u određenom području, potrebno je uložiti dodatni napor da razumije kako tumačiti podatke. Ovim zajedničkim radom postavili smo nove standarde u prikazima podataka, primijenili smo Renault vizualni identitet i učinili da izvještaji budu razumljivi svima zainteresiranim. Osim toga, radimo i na pojednostavljenju prikaza, kako bi poboljšali ergonomiju i učinili prikaz rezultata zanimljivim i onima koji nisu direktno uključeni u ostvarivanje rezultata. Idući veliki izazov je da prikažemo pravi podatak u pravo vrijeme i na pravom uređaju korisnika, za što očekujemo podršku od novih tehnologija koje

⁵⁰ Adacta „Renault Nissan Hrvatska“ <http://www.adacta.hr/case-studies/renault-nissan> (24.8.2017.)

donosi Qlik, a najznačajnije nam je iskustvo i znanje Adacte” za Adactu su istaknuli u Renault Nissanu Hrvatska

Jadran Galenski Laboratorij (JGL) jedna je od vodećih farmaceutskih organizacija u Hrvatskoj. Na tržištu je prisutna od davne 1992. godine, a od tada do danas ova organizacija neprestano raste. Konstantne inovacije i unaprjeđenja osigurali su im vodeću poziciju na tržištu, koja je uz želju za proširenjem poslovanja na područje šire Europe rezultirala potrebom za korištenjem dobrog alata za analizu i vizualizaciju podataka. Prije uspostave alata IBM iz serije Analytics, podaci nisu bili centralizirani te nije postojao jedinstveni uvid u cjelokupno poslovanje, a izvještavanje i provođenje analiza nad podacima bilo je teško i vremenski zahtjevno. Uvođenjem alata za vizualizaciju podataka omogućeno je centralizirano prikupljanje podataka, jednostavna obrada velikih količina podataka, vizualan i brz prikaz svih informacija te strateško planiranje na temelju trenutnih i točnih informacija iz organizacije i okruženja.⁵¹

Hrvatska banka za obnovu i razvoj (HBOR) razvojna je i izvozna banka Republike Hrvatske, sa osnovnim ciljem poticanja razvoja hrvatskog gospodarstva. Ova organizacija ima 349 zaposlenih, čime spada u srednje velike. Osnovne aktivnosti su kreditiranje, osiguravanje izvoza od političkih i komercijalnih rizika, izdavanje garancija i poslovno savjetovanje organizacijama kako bi se olakšao izvoz i plasman proizvoda lokalnih poduzeća na Hrvatsko i svjetsko tržište. Kako je došlo do povećanja broja organizacija i projekata koje HBOR podržava razvila se potreba za jedinstvenim rješenjem koje će im omogućiti praćenje poslovnih procesa i aktivnosti te pružiti uvid u podatke s kojima raspolažu. Idealno rješenje pronašli su u implementaciji Microsoft Power BI alata za vizualizaciju podataka koje se nadogradilo na postojeći Microsoftov sustav skladišta podataka. Implementacijom alata Power BI HBOR je stekao uvid u sve procese i aktivnosti na jednom mjestu, kao i mogućnost obrade velikih količina podataka i provođenja kompleksnih analiza na jednostavan način. Korištenjem interaktivnih sučelja donositelji odluka mogu jednostavno i brzo vidjeti veze

⁵¹ IBM Corporation „Jadran Galenski Laboratorij“, 2011. <http://www.inteligencija.com/o-nama/projekti/jgl/> (24.8.2017.)

među podacima, sagledati podatke iz različitih perspektiva i shvatiti uzroke odstupanja te reagirati na promjene.⁵²

„Power BI omogućio nam je povezivanje različitih vrsta podataka iz raznih izvora podataka i provođenje detaljnih analiza, kao i korištenje interaktivnih izvještaja, što je osiguralo poboljšanje produktivnosti i efikasnosti zaposlenika i cjelokupne organizacije. Zahvaljujući modernoj tehnologiji imamo pristup pravovremenim poslovnim analizama u svakom trenutku, kao i uvid u utjecaj našeg poslovanja na ekonomiju države.“ Izjavio je za Microsoft Goran Filipić, član odbora u HBOR-u.

5.2. Kako primjena alata za vizualizaciju podataka utječe na poslovanje Hrvatskih organizacija

Alati za vizualizaciju podataka u Hrvatskim organizacijama, kao i u globalnim, implementiraju se s ciljem poboljšanja poslovanja, unaprjeđenja poslovnih procesa i mogućnosti donošenja kvalitetnih i brzih odluka temeljenih na razumijevanju promjena koje se događaju u organizaciji, kako bi se na vrijeme prilagodilo dinamičnom i sve zahtjevnijem tržištu. Sve Hrvatske organizacije koje su implementirale alate za vizualizaciju podataka, zabilježile su značajno poboljšanje poslovanja, od optimizacije poslovnih procesa, isporuke kvalitetnijih proizvoda ili usluga te brže i lakše reakcije na promjene na tržištu pa do bolje informiranosti zaposlenika, kvalitetnijeg radnog okruženja i porasta profita.

„Poboljšano praćenje i razumijevanje podataka pružilo nam je potpunu kontrolu nad ciklusom planiranja, što nam je omogućilo optimizaciju nabave i proizvodnje, te konstantan rast organizacije uz niže troškove.“ Izjavila je za IBM Elvedina Kežman, CRM i Marketing menadžer za kontrolu u Jadran Galenskom Laboratoriju.

“Prilikom predstavljanja novih izvještaja putem QlikView, na novi i vizualno stimulativan način, uočili smo gdje se nalaze greške u unosima podataka. Nešto što se mjesecima skupljalo, uprava je uspjela prepoznati u iznimno kratkom roku i poduzeti akcije koje su

⁵² Microsoft „With Power BI implementation HBOR now has fast and accurate insights into its business activities, any time and on all mobile platforms“, 2016. <https://customers.microsoft.com/en-us/story/with-power-bi-implementation-hbor-now-has-fast-and-acc> (24.8.2017.)

greške otklonile. Sada se vrijeme za uočavanje grešaka smanjilo, a samim time i broj grešaka.” Istaknuli su za Adactu iz Renault Nissan Hrvatska

Po našim grubim procjenama već sada možemo reći da štedimo oko pola čovjeka na ovim repetitivnim poslovima i generiranju izvještaja, jer to danas za nas obavlja QlikView. Iskustvo koje smo dobili od Adacte je vrijedno, posebno savjeti koje smo iskoristili da promijenimo standardan način razmišljanja i tako se maknemo iz našeg okruženja.” - Gosp. Dario Petrović, IT direktor, tvrtke Renault Nissan Hrvatska d.o.o. izjavio je za Adactu nakon prvih nekoliko tjedana korištenja alata Qlik.

Orbico grupa vodeći je distributer robe široke potrošnje u Hrvatskoj i Europi, kao takva velika organizacija prisutni su na sedamnaest tržišta i objedinjuju četrdeset kompanija, te im je prijeko potreban kvalitetan sustav za potporu poslovnom odlučivanju, analitiku i vizualizaciju podataka. Kako bi osigurali jedinstvenost izvještavanja i omogućili pristup informacijama svima kojima su one potrebne u cijeloj organizaciji, Orbico se odlučio na jedno, sveobuhvatno rješenje koje će osigurati provođenje analiza nad podacima s kojima raspolažu i distribuciju informacija kroz cijelu Orbico Grupu. Odlučili su se na implementaciju IBM Analytics alata, koji omogućava povezivanje svih dijelova organizacije, provođenje kompleksnih analiza i vizualno izvještavanje, kako bi svi donositelji odluka mogli imati lak i brz pristup aktualnim informacijama.

Romana Orešković, Financijski direktor u Obicu, izjavila je „*Najveći izazov s kojim se suočavamo jest pronalazak najboljeg načina za pružanje kvalitetne usluge našim dobavljačima, kupcima i financijskim institucijama. Kako bi otkrili način kako biti najbolji partner svima, potreban nam je kvalitetan i opsežan uvid u naše podatke.*“

Uspostavom rješenja za analitiku i vizualizaciju podataka, Obico je stekao uvid i iskoristio sve podatke s kojima raspolaže, omogućeno je provođenje detaljnih i kompleksnih analiza koje osiguravaju optimizaciju i poboljšanje poslovnih procesa te isporuku proizvoda i usluga. Također pružen je uvid u poslovanje svih poduzeća koja posluju na različitim tržištima u Europi, te je omogućena analiza svakog tržišta zasebno. Na ovaj način osigurano je kvalitetno planiranje i uspostava strategije poslovanja temeljena na kvalitetnim i točnim informacijama, u svakoj regiji pojedinačno. Uspostavom ovog kvalitetnog rješenja za analizu, planiranje i vizualizaciju omogućeno je praćenje poslovanja i prilagodba promjenjivim uvjetima na

tržištu, što je u konačnici rezultiralo boljim i uspješnijim poslovnim rezultatom Grupe. Uz to, zbog primjene alata na financijskom području, što je omogućilo bolju konsolidaciju podataka Orbico je ostvario i bolji rejting od strane financijskih institucija, što je uzrokovalo sniženje troškova kreditiranja.⁵³

„IBM Analytics rješenje pomoglo nam je iskoristiti prilike koje se ukazuju kako bi uštedjeli vrijeme i novac te brže reagirali na promjene zahtjeva na tržištu, što je ključna prednost u dinamičnoj industriji kao što je distribucija.“ Kaže Romana Orešković za IBM.

Alca je europska organizacija koja se bavi distribucijom i logistikom sa podružnicama u brojnim zemljama, među kojima je i Hrvatska, Srbija i Slovenija. U podružnicama ovih zemalja implementiran je alat Qlik kako bi se olakšalo poslovanje, praćenje poslovnih procesa i izvještavanje. Prije implementacije alata za vizualizaciju podataka u organizacijama je postojao ERP sustav baziran na Oracle platformi koji se iskoristio za nadogradnju alata Qlik koji će omogućiti vizualizaciju podataka i jednostavno izvještavanje. Međutim, nisu svi podaci bili u ERP sustavu pa je Qlik-ova sposobnost povezivanja na više izvora podataka bila od iznimnog značaja.

Kako bi se postiglo praćenje cjelokupnog poslovanja i uvid u sve informacije te standardiziranost izvještavanja Adacta je morala provesti prilagodbe organizacije i samog alata te obučiti korisnike za upotrebu alata. Međutim, naponi su se isplatili, jer je uspješna implementacija alata Qlik osigurala smanjenje vremena potrebnog za provedbu analiza sa jednog dana, koliko je bilo potrebno prije implementacije, na svega nekoliko minuta koliko je potrebno korisnicima uz alat Qlik. Ova značajna ušteda vremena rezultirala je uštedom novca te bržim i jednostavnijim donošenjem odluka temeljenih na pravodobnim i točnim informacijama. Omogućeno je i mjerenje ključnih indikatora poslovanja čime je povećana efikasnost poslovanja i ostvarena bolja realizacija prodaje od strane prodajnih predstavnika.⁵⁴

Adriatic Sailing jedna je od vodećih organizacija za najam brodova u Hrvatskoj. Sa flotom od dvadeset šest jahti, dvanaest zaposlenih i preko 4000 rezervacija ova mala organizacija razvila je potrebu za sustavom za praćenje poslovanja i vizualizaciju podataka. Kao posljedica velikog obujma posla generirala se velika količina podataka na dnevnoj razini te je bilo

⁵³ Poslovna inteligencija „Orbico“ <http://www.inteligencija.com/o-nama/projekti/orbico/> (25.8.2017.)

⁵⁴ Adacta „Alca“ <http://www.adacta.hr/case-studies/alca> (25.8.2017.)

potrebno mnogo vremena za stvaranje izvještaja i prikupljanje tih podataka iz različitih izvora. Excel tablice koje su koristili za kreiranje izvještaja nisu bile dovoljno napredne za potpuno razumijevanje podataka, a oduzimale su mnogo vremena za sastavljanje i kreiranje izvještaja. Kako bi riješili ovaj problem uposlili su Microsoft partnera 3 PRO koji im je pomogao u implementaciji jednog, sveobuhvatnog rješenja za praćenje poslovanja, analizu i izvještavanje, Power BI.

Nakon implementacije alata za vizualizaciju podataka Power BI informacije o cjelokupnom poslovanju dostupne su preko jednog interaktivnog sučelja koje je u potpunosti prilagođeno potrebama i zahtjevima korisnika. Na vrlo jednostavan način korisnici mogu provoditi kompleksne analize i rezultate dobiti u vizualnom obliku koji omogućava razumijevanje utjecaja različitih čimbenika na rezultate poslovanja. Adriatic Sailing sada ima mogućnost pristupa svim podacima na jednom mjestu uz brojne opcije prilagodbe prikaza podataka i brze izrade sveobuhvatnih izvještaja. Također omogućen je i pristup informacijama sa raznih uređaja kao što su mobilni telefoni i tableti.⁵⁵

„Zahvaljujući alatu Power BI Adriatic Sailing može kreirati izvještaje korištenjem različitih podataka iz različitih izvora brže i efikasnije nego prije. To nam osigurava da više vremena posvetimo poslovnim aktivnostima koje donose profit direktno u našu organizaciju.“ Izjavio je za Microsoft Jakov Bošnjak Izvršni direktor u Adriatic Sailing.

U konačnici može se zaključiti kako je primjena alata za vizualizaciju u organizacijama jedan od ključnih čimbenika za kvalitetno i uspješno poslovanje. Hrvatske organizacije implementacijom navedenih alata osigurale su optimizaciju poslovanja, uštedu vremena i novca, bolje praćenje stanja poslovnih procesa te bržu i kvalitetniju reakciju na promjene na tržištu. Korištenjem alata za vizualizaciju osiguran je detaljan uvid organizacija u cjelokupno poslovanje i pokazatelje učinkovitosti čime je omogućeno djelovanje na procese i aktivnosti koje imaju lošije rezultate i u na posljetku ostvarenje boljeg poslovnog rezultata uz isporuku kvalitetnijeg proizvoda ili usluge.

⁵⁵ Microsoft „Power BI: business intelligence to increase productivity“, 2017.

<https://customers.microsoft.com/en-us/story/adriatic-sailing-hospitality-and-travel-office365-azure-app-service-sharepoint-online-powerbi-en> (26.8.2017.)

Hrvatske organizacije koje još nisu implementirale alate za vizualizaciju podataka u svoje poslovanje teško razume ili pak uopće nemaju pristup svojim podacima, što ih čini manje konkurentnima u odnosu na one koje koriste navedene alate. Ove organizacije nemaju uvid u svakodnevno poslovanje, nemaju mogućnost reakcije na tržišne promjene iz jednostavnog razloga, jer ih ne vide na vrijeme. Ukoliko imaju implementiran sustav za poslovnu inteligenciju, analize su kompleksne i zahtjevne, a korisnicima se isporučuju statični standardizirani izvještaji koji ne pružaju mogućnost dodatnog uvida u informacije kao ni mogućnost razumijevanja utjecaja pojedinih čimbenika na druge. Uz to do trenutka kada se izvještaji za donositelje odluka sastave, informacije koje su u izvještajima već su zastarjele, stoga se odluke konstantno donose na temelju „povijesnih“ informacija, umjesto trenutnih. Alati za vizualizaciju podataka pružaju mogućnost organizacijama da budu u toku sa svojim poslovanjem i stanjem u organizaciji i na tržištu, omogućuju im rast i razvoj te konkuriranje na tržištu, bilo hrvatskom, europskom ili svjetskom.

5.3. Najveći problemi hrvatskih organizacija vezani uz alate za vizualizaciju podataka

„Vizualizacija podataka je mnogo više od lijepog izgleda informacija.“ Cindi Howson, osnivač BI Scorecard.

Vizualizacija podataka u posljednjih nekoliko godina jedan je od najbrže rastućih trendova na području poslovne inteligencije i zasigurno jedna od najpopularnijih tema na današnjim BI konferencijama. Alati za vizualizaciju podataka omogućavaju ne samo privlačan vizualan prikaz informacija, već i dubinske analize te razumijevanje načina na koji poslovni procesi i aktivnosti utječu jedni na druge. S porastom popularnosti ovih alata raste i broj njihovih implementacija, kako u svijetu tako i u Hrvatskoj, međutim, prilikom odabira i implementacije alata organizacije nailaze i na neke probleme koje je potrebno riješiti kako bi se alat uspješno uveo u poslovanje i počeo aktivno primjenjivati.

Problem izvještavanja.

Vizualizacija podataka pomaže korisnicima da bolje razumiju informacije i donose bolje i informirane odluke. Grafički prikazi trebaju biti jednostavni i sveobuhvatni te se treba omogućiti brže shvaćanje velike količine informacija. Ukoliko to ne omogućavaju ili

informacije prezentiraju na teško razumljiv i kompleksan način, ne ispunjavaju svoju svrhu u organizaciji te dolazi do problema efikasnosti korištenog alata.⁵⁶ Dakle prvi problem s kojim se organizacije susreću, kako u svijetu tako i u Hrvatskoj, jest prilagodba izvještaja potrebama svoje organizacije. Naime, događa se da sustav analizira velike količine informacija i prezentira ih korisnicima, ali ukoliko ne postoji personalizacija izvještaja, svim korisnicima isporučuju se isti, sveobuhvatni izvještaje, koji sadrže više desetaka stranica. Na ovaj način korisnici imaju pristup svim informacijama, uključujući i onim koje im nisu potrebne, a traženje informacija koje im trebaju oduzima vrijeme. Tada dolazi do značajnog gubitka vremena, a informacije postaju gotovo beskorisne, kao i alat za vizualizaciju. Stoga organizacija koja provodi implementaciju na umu treba imati korisnike alata i izvještaja, te alat treba odabrati i konfigurirati na temelju specifičnih potreba i zahtjeva organizacije.

Problem odabira alata.

S obzirom da hrvatske organizacije najčešće prilikom odabira alata za vizualizaciju podataka promatraju svoje konkurente, bilo na svjetskom ili lokalnom tržištu, pogrešan odabir alata za vizualizaciju ili pogrešna konfiguracija postavki, koja ne odgovara načinu poslovanja organizacije, čest je slučaj. Naime, dvije organizacije koje posluju u istom sektoru ne moraju nužno imati iste potrebe i zahtjeve po pitanju vizualizacije podataka, stoga ni alat koji odgovara jednoj organizaciji, ne mora nužno odgovarati drugoj. Ovakvi problemi poprilično se dobro izbjegavaju ukoliko se angažira organizacija specijalizirana za implementaciju rješenja za vizualizaciju podataka, koja tada može procijeniti poslovanje organizacije i predložiti najbolje rješenje. Međutim, ponekad se i tada pojavljuju problemi, jer predloženi alati nisu uvijek idealno rješenje koje su korisnici zamislili ili su pak rješenja skuplja od očekivanog. Prilikom odabira alata za vizualizaciju podataka, organizacija treba uzeti u obzir koje je najbolje rješenje za njene potrebe. Dakle treba analizirati svoje poslovanje i definirati područja za koja se želi uspostaviti izvještavanje, kao i u koje podatke želi imati uvid, odnosno koji podaci su najvrjedniji za poslovanje. Na temelju takve analize treba se odabrati alat koji će najbolje zadovoljiti sve potrebe i zahtjeve organizacije.

⁵⁶ Burns, E. „Data visualization tools may be glamorous, but focus on business value“, SearchBusinessAnalytics <http://searchbusinessanalytics.techtarget.com/feature/Data-visualization-tools-may-be-glamorous-but-focus-on-business-value> (26.8.2017.)

Problem visokih očekivanja.

Treći problem prilikom implementacije alata za vizualizaciju podataka javlja se zbog očekivanja koja korisnici imaju od alata. Naime, većina korisnika, posebice onih manje informiranih i upućenih u temu vizualizacije podataka, od alata očekuju idilične prikaze informacija, 3D grafike i brojne druge karakteristike koje uglavnom nisu dostupne. Uz to, korisnici često zanemaruju činjenicu kako je alat za vizualizaciju samo sredstvo prikaza informacija, koje im omogućava uvid u poslovanje poduzeća na temelju čega bi trebali donositi odluke, pa od alata očekuju i prezentaciju najboljih rješenja za poslovne probleme s kojima se susreću. Naravno, najbolji svjetski alati za vizualizaciju, poput Tableau-a, Power BI, Qlik i drugih, pružaju široke opcije vizualizacija i grafičkih prikaza, kao i brojne mogućnosti personalizacije i detaljnih analiza, ali ni jedan ne nudi rješenja poslovnih problema. Također, većina ostalih alata, posebice ako nisu specijalizirani za vizualizaciju, već poslovnu analitiku, imaju jako ograničene mogućnosti vizualnih prikaza. Korisnici koji implementiraju ovakve alate u nadi za objedinjenjem svih rješenja pod jednu platformu, najčešće se razočaraju mogućnostima vizualizacije, koje su često ograničene na jednostavne grafičke prikaze i usporedbe.⁵⁷ S obzirom na generalno lošu informiranost o alatima za vizualizaciju u Hrvatskoj, može se zaključiti kako je ovo poprilično čest problem kod lokalnih poduzeća. Srećom, hrvatski predstavnici za poznate svjetske alate dobro su informirani te nastoje držati očekivanja korisnika unutar granica mogućnosti alata koji je odabran za implementaciju.

Problem promjena u organizaciji.

Četvrti problem koji se javlja prilikom implementacije alata za vizualizaciju podataka odnosi se na promjene u poslovanju organizacije koje je potrebno provesti kako bi implementacija alata bila uspješna, uz mogućnost iskorištavanja svih prednosti alata za vizualizaciju. Može se reći da se implementacija alata za vizualizaciju sastoji od četiri dijela: jedan dio čini tehnologija, drugi analitika i dva dijela čini upravljanje promjenama.⁵⁸ Na ovaj problem naišle su i hrvatske organizacije prilikom implementacije alata za vizualizaciju. Naime kako bi se

⁵⁷ Op.cit. Burns, E. „Data visualization tools may be glamorous, but focus on business value“

⁵⁸ Polsky, A. „Data Visualization:7 Considerations for Visualization Deployment“ International Institute for Analytics, 2013.

<https://theartofservicelab.s3.amazonaws.com/All%20Toolkits/The%20Data%20Visualization%20Toolkit/Act%20-%20Recommended%20Reading/Data%20Visualization-.pdf> (26.8.2017.)

uspješno provela implementacija, potrebno je reorganizirati poslovanje i promijeniti način razmišljanja u poduzeću. To je zahtjevan proces koji se ne može provesti bez potpore i suradnje vrhovnog menadžmenta. U prethodno navedenim organizacijama ovaj problem pojavio se i razriješio suradnjom iskusnih organizacija koje su provodile implementaciju i zaposlenika poduzeća. Međutim, ukoliko se ovakvi problemi ne riješe uspješno, alat za vizualizaciju može biti implementiran u organizaciju, ali neće isporučivati očekivane rezultate niti će omogućiti unaprjeđenje poslovanja. Stoga je značajno da organizacije prilikom odluke o implementaciji alata za vizualizaciju podataka budu spremne ne samo na promjene u načinu izvještavanja, već i na promjene cjelokupnog poslovanja.

6. Zaključak

U ovom radu kratko je objašnjena poslovna inteligencija kao cjelina te njezina primjena u današnjim organizacijama. Definirani su ovogodišnji trendovi u poslovnoj inteligenciji, a kao najznačajniji među njima pokazala se vizualizacija podataka. Kratko je prikazano i stanje vezano uz poslovnu inteligenciju u Hrvatskoj, te je zaključeno da velika većina organizacija, od velikih do manjih koristi barem neki oblik poslovne inteligencije u svojem poslovanju. U posljednjih nekoliko godina broj implementiranih sustava poslovne inteligencije u Hrvatskoj značajno se povećao, zbog utvrđivanja potrebe za iskorištavanjem podataka s kojima organizacije raspolažu.

Kao dio poslovne inteligencije predstavljena je i objašnjena vizualizacija podataka. Ovo značajno područje pomaže korisnicima razumjeti podatke s kojima raspolažu, olakšava provođenje kompleksnih analiza vizualizirajući procese i omogućava donositeljima odluka bolji uvid u trenutno stanje organizacije putem interaktivnih sučelja. Vizualizacija podataka nezamjenjiva je u organizacijama koje žele ostati konkurentne na tržištu, a to je dokazano kroz nekoliko primjera primjene vizualizacije podataka u poznatim svjetskim organizacijama. Prikazano je kako vizualizacija podataka pomaže organizacijama u ostvarenju njihovih ciljeva, rastu i razvoju te unaprjeđenju poslovanja. Vizualizacija je ovim organizacijama omogućila razumijevanje podataka s kojima raspolažu, shvaćanje poslovnih procesa, optimizaciju istih. Omogućila je menadžerima lakše i jednostavnije donošenje boljih i informiranih odluka te planiranje, kako na operativnoj i taktičkoj, tako i na strateškoj razini. U

konačnici može se reći kako je upravo vizualizacija podataka zaslužna za današnji uspjeh navedenih organizacija.

Potom je kratko prikazana vizualizacija podataka u Hrvatskoj, iako je njena primjena u odnosu na svijet značajno manja, te je informiranost korisnika u Hrvatskoj niska, ipak se kreće ka sve većoj implementaciji i korištenju alata za vizualizaciju podataka. Može se reći da malo kasnimo za ostatkom razvijenih zemalja ali krećemo se naprijed. Vizualizacija se u Hrvatskoj primarno koristi u javnom sektoru te među velikim organizacijama koje posluju na području cijele zemlje, Europe ili svijeta. Sve veća informiranost o ovoj temi doprinosi interesu manjih i srednjih organizacija za vizualizaciju podataka, te se u posljednjih dvije godine značajno povećala potražnja za alatima koji organizacijama omogućavaju optimizaciju i praćenje poslovanja i uvid u podatke na jednostavan i vizualan način.

Nakon razrade pojma vizualizacije te primjene i prednosti koje donosi u poslovanju objašnjeni su alati za vizualizaciju podataka. Definirane su najznačajnije karakteristike ovih alata koje su neizostavne za unaprjeđenje poslovanja i ostvarenje njihove uloge u organizaciji. Neke od spomenutih karakteristika su mogućnost jednostavnog provođenja analiza, minimalna potreba za kodiranjem, mogućnost grafičkog prikazivanja svih vrsta podataka, spajanje na brojne izvore podataka kao i mogućnost obrade velikih količina podataka. Jednostavno dijeljenje informacija među zaposlenicima također je značajno. S korisničke strane definirana su očekivanja od alata za vizualizaciju, a ona obuhvaćaju jednostavnost upotrebe i razumijevanja prezentiranih informacija, praćenje poslovnih procesa, mogućnost utvrđivanja veza među podacima te prediktivna analiza.

Po utvrđivanju ovih karakteristika objašnjeni su najpoznatiji svjetski alati za vizualizaciju podataka, kratko su definirane njihove karakteristike, mogućnosti i kvalitete, nakon čega je provedena usporedba navedenih alata, s obzirom na kriterije izvedene iz funkcionalnosti alata koje su se pokazale kao najznačajnije za unaprjeđenje poslovanja organizacije. Koristila se AHP metoda za višekriterijalno odlučivanje te alat SuperDecisions. Provedenom analizom utvrđeno je kako su svjetski lideri na tržištu zaista i najbolji alati u odnosu na postavljene kriterije te su definirane osnovne prednosti i nedostaci alata s obzirom na svaki kriterij zasebno.

Hrvatski alati za vizualizaciju podataka predstavljeni su nakon obrade svjetskih alata, a utvrđene su i njihove karakteristike. Jedan od alata za vizualizaciju podataka hrvatske proizvodnje, BusinessQ, usporedio se sa svjetskim alatima i postigao jako dobre rezultate. Također su definirane karakteristike alata koje bi se trebale unaprijediti kako bi bio pravi konkurent na svjetskom tržištu. Nažalost ostali alati proizvedeni u Hrvatskoj su specijalizirani za jedno područje poslovanja te se nisu uspoređivali sa svjetskim alatima koji napravljeni za podršku poslovanja cijele organizacije.

U hrvatskim se organizacijama sve više primjenjuju poznati svjetski alati među kojima i oni obrađeni u ovom radu. Stoga je primjerima implementacije i primjene tih alata u hrvatskim organizacijama prikazano na koji način i u koje svrhe se alati primjenjuju, kako su implementirani i kako su poboljšali poslovanje organizacija. Utvrđeno je da se alati za vizualizaciju podataka implementiraju kako bi unaprijedili poslovanje, optimizirali poslovne procese i korisnicima omogućili detaljan ali pregledan uvid u informacije o poslovanju, uz olakšavanje provođenja kompleksnih analiza kao i vizualnu analizu koja korisnicima omogućava samostalno istraživanje međusobnih utjecaja procesa i detaljne analize podataka. Prikazani su i pozitivni utjecaji na poslovanje organizacija koji su rezultat uvođenja alata za vizualizaciju podataka. U konačnici istraženi su najveći problemi s kojima se organizacije susreću prilikom implementacije i korištenja alata za vizualizaciju podataka. Naglasak je stavljen na Hrvatske organizacije, iako se sa istim problemima susreću sve organizacije koje implementiraju alate za vizualizaciju.

Sažetak

U ovom radu definirani su pojmovi poput poslovne inteligencije i vizualizacije podataka. Istaknuti su zanimljivi trendovi u poslovnoj inteligenciji te je kroz primjere prikazana uloga najznačajnijeg od njih, vizualizacije podataka, u poslovanju svjetskih i hrvatskih organizacija. Prikazan je i njezin utjecaj na poslovanje poduzeća, kako svjetskih tako i hrvatskih. Poblje su obrađeni najpoznatiji svjetski alati za vizualizaciju Tableau, Microsoft Power BI, Qlik, SAP Lumira, IBM Watson Analytics, Oracle i Pentaho. Navedeni alati je uspoređen s obzirom na kriterije koji su se pokazali kao značajni za poslovanje organizacije, a potom je uspoređen i hrvatski alat za vizualizaciju, BusinessQ, sa svjetskim. Definirane su osnovne karakteristike hrvatskog alata za vizualizaciju koje se trebaju unaprijediti kako bi bio konkurentan na svjetskom tržištu. Potom je prikazana primjena svjetskih alata u hrvatskim organizacijama te su istaknuti najveći problemi prilikom implementacije i korištenja alata za vizualizaciju podataka.

Ključne riječi: vizualizacija podataka, alati za vizualizaciju podataka, vizualizacija podataka u Hrvatskoj

Summary

In this paper, concepts like business intelligence (BI) and visual analysis are presented and defined. Interesting trends in BI are highlighted and, as one of the most important trends, data visualization is presented through examples of use in the companies in Croatia and the world. Also, the effect of data visualization on businesses is presented. The most popular data visualization tools such as Tableau, Microsoft Power BI, Qlik, SAP Lumira, IBM Watson Analytics, Oracle and Pentaho, are presented and analyzed. The analyses is conducted with regard to criteria that are established to be valuable for business organizations. Afterwards, Croatian data visualization tool, BusinessQ, is compared to world's best tools for data analysis. As a result, characteristics of the tool which has to be improved so it could be competitive are defined. Then, the use of worlds' most popular tools in Croatian companies is presented and the biggest problems with implementation and use of data visualization tools are highlighted.

Key words: data visualization, data visualization tools, data visualization in Croatia

Literatura

1. 123ahp „Metoda izračuna“, [Internet], raspoloživo na:
<http://www.mojizbormojaodluka.net/OMetodi.aspx>
2. Adacta „Alca“, [Internet], raspoloživo na: <http://www.adacta.hr/case-studies/alca>
3. Adacta „Renault Nissan Hrvatska“ [Internet], raspoloživo na:
<http://www.adacta.hr/case-studies/renault-nissan>
4. Al-Hassani, Yass „Why is BI important to your company?“, [Internet], raspoloživo na:
<https://www.linkedin.com/pulse/why-business-intelligence-bi-important-your-company-yass>
5. Barth, Paul: (2017) „The rise of the data marketplace“, [Internet], raspoloživo na:
<http://www.cio.com/article/3184575/business-intelligence/the-rise-of-the-data-marketplace.html>
6. Beroš, I. (2017) „Statističke metode u forenzičkoj analizi“, [Internet], raspoloživo na:
<http://www.poslovnaucinkovitost.eu/kolumne/poslovanje/492-grafovi-u-exceluzasto-slika-vrijedi-vise-od-tisucu-rijeci-ili-brojki.html>
7. Bičak D. (2016) „Danas sve ozbiljne tvrtke provjeravaju svoje buduće poslovne partnere, a mi smo njihove oči i uši“, Poslovni Dnevnik, [Internet], raspoloživo na:
<http://www.poslovni.hr/poduzetnik/danas-sve-ozbiljne-tvrtke-provjeravaju-svoje-buduce-poslovne-partnere-a-mi-smo-njihove-oci-i-usi-315266>
8. BI-SURVEY (2017) „Top Business Intelligence Trends 2017: What 2,800 BI Professionals Really Think“, [Internet], raspoloživo na: <https://bi-survey.com/top-business-intelligence-trends-2017>
9. Bosilj Vukšić, Vesna; Ćurko, Katarina; Merkaš, Zvonko (2016): Usage of Business Intelligence technology in Croatia: Preliminary research, WSEAS TRANSACTIONS on BUSINESS and ECONOMICS, Zagreb, [Internet], raspoloživo na:
<http://www.wseas.org/multimedia/journals/economics/2016/b105807-075.pdf>
10. Blagović, L. (2016) „Vizualizacija podataka u sustavu poslovne inteligencije“, Sveučilište Jurja Dobrile u Puli, Pula, [Internet], raspoloživo na:
<https://dr.nsk.hr/islandora/object/unipu%3A794/datastream/PDF/view>
11. Burns, E. (2013) „Data visualization tools may be glamorous, but focus on business value“, [Internet], raspoloživo na:
<http://searchbusinessanalytics.techtarget.com/feature/Data-visualization-tools-may-be-glamorous-but-focus-on-business-value>

12. DataSimplified „Modern city. Informed citizens.“, [Internet], raspoloživo na: <http://www.datasimplified.com/c2c.php>
13. Davis, Jessica: (2016) „10 Data Visualization Tools To Bring Analytics Into Focus“, [Internet], raspoloživo na: <http://www.informationweek.com>
14. Dholakiya, Pratik (2017) „Look for These 5 Business Intelligence Tool Attributes to Effectively Drill Into Big Data“, [Internet], raspoloživo na: <https://www.entrepreneur.com>
15. Gibson, S. (2017) „GARTNER MAGIC QUADRANT FOR BUSINESS INTELLIGENCE 2017 – CLOUD IS COMING (SLOWLY)“, [Internet], raspoloživo na: <http://optimalbi.com/blog/2017/02/17/gartner-magic-quadrant-for-business-intelligence-2017-cloud-is-coming-slowly/>
16. Glojnarić, V. (2017) „Tvrtke žele prediktivnu analitiku kao dio standardne ponude BI alata“, BIZdirekt, [Internet], raspoloživo na: <http://www.mirakul.hr/bizdirekt/tvrtke-zele-prediktivnu-analitiku-dio-standardne-ponude-alata/>
17. Grizelj Šimić, V. (2014) „GIS i njegova primjena u hidrologiji i suvremenom vodnogospodarskom planiranju“, Hrvatske vode, V88, pg. 119-130, [Internet], raspoloživo na: http://www.voda.hr/sites/default/files/pdf_clanka/hv_88_2014_119-130_grizeljsimic.pdf
18. Harris, Daniel (2017) „FrontRunners for Business Intelligence“, [Internet], raspoloživo na: <http://www.softwareadvice.com/bi/#top-products>
19. Hawton, J. (2016) „Picture-Perfect Data Models Help Build Better Products“, Technology, [Internet], raspoloživo na: <http://www.boeing.com/features/2016/06/casa-06-16.page>
20. Heinze, J. (2017) „Pentaho Business Intelligence Review“, [Internet], raspoloživo na: <https://www.betterbuys.com/bi/reviews/pentaho-business-intelligence/>
21. IBM Corporation (2011) „Jadran Galenski Laboratorij“, [Internet], raspoloživo na: <http://www.inteligencija.com/o-nama/projekti/jgl/>
22. IBM Watson Analytics, [Internet], raspoloživo na: <https://www.ibm.com/watson-analytics>
23. Ivezić B. (2016) „BI i CRM projekti ojačali Adactu“, Poslovni Dnevnik, [Internet], raspoloživo na: <http://www.poslovni.hr/tehnologija/bi-i-crm-projekti-ojacali-adactu-310214>
24. Kerschberg, B. (2014) „Five Key Properties of Interactive Data Visualization“, Forbes, [Internet], raspoloživo na:

- <https://www.forbes.com/sites/benkerschberg/2014/04/30/five-key-properties-of-interactive-data-visualization/#118bef98589e>
25. Kutleša, J. (2017) „Facebook Data Analytics“, [Internet], raspoloživo na: <http://blog.inteligencija.com/facebook-data-analytics/>
26. Lebed, Mona (2016) „Top 11 Business Intelligence and Analytics Trends for 2017“ [Internet], raspoloživo na: <http://www.datapine.com/blog/>
27. Lider.media (2016) „CROračun i PROračun – alati za vizualizaciju lokalnih proračuna“, [Internet], raspoloživo na: <https://lider.media/aktualno/biznis-i-politika/hrvatska/croracun-i-proracun-alati-za-vizualizaciju-lokalnih-proracuna/>
28. Lorica, B. (2016) „11 essential features that visual analysis tools should have“, [Internet], raspoloživo na: <https://www.oreilly.com/ideas/11-essential-features-that-visual-analysis-tools-should-have>
29. Microsoft „Power BI (2017) „business intelligence to increase productivity“, [Internet], raspoloživo na: <https://customers.microsoft.com/en-us/story/adriatic-sailing-hospitality-and-travel-office365-azure-app-service-sharepoint-online-powerbi-en>
30. Microsoft (2016) „With Power BI implementation HBOR now has fast and accurate insights into its business activities, any time and on all mobile platforms“, [Internet], raspoloživo na: <https://customers.microsoft.com/en-us/story/with-power-bi-implementation-hbor-now-has-fast-and-acc>
31. MIT software, [Internet], raspoloživo na: <http://www.mit-software.hr/usluge/bi/bi1/>
32. Morgan, J. „Requirements for Visualization Software“, [Internet], raspoloživo na: <http://usabilityetc.com/articles/visualisation-software-requirements/>
33. Neos.hr „HEP - Business Intelligence system“, [Internet], raspoloživo na: <http://www.neos.hr/about-us/references/?show=hep-bussiness-intelligence-system>
34. Neos.hr „ZABA – BI consulting“, [Internet], raspoloživo na: <http://www.neos.hr/about-us/references/?show=zaba-bi-consulting>
35. Oracle „Oracle Data Visualization“, [Internet], raspoloživo na: <https://www.oracle.com/solutions/business-analytics/data-visualization/capabilities.html>
36. Qlik, [Internet], raspoloživo na: <http://www.qlik.com/us/>
37. Qualia – Data Visualization, [Internet], raspoloživo na: <http://www.qualia.hr/services/data-visualization/>

38. Pejic Bach, M., Strugar, I., Simicevic, V. (2010) „Determinants of business intelligence usage in Croatian large companies“, Beč, [Internet], raspoloživo na: <http://www.freepatentsonline.com/article/Annals-DAAAM-Proceedings/246013830.html>
39. Polsky, A. (2013) „Data Visualization:7 Considerations for Visualization Deployment“ International Institute for Analytics, [Internet], raspoloživo na: <https://theartofservicelab.s3.amazonaws.com/All%20Toolkits/The%20Data%20Visualization%20Toolkit/Act%20-%20Recommended%20Reading/Data%20Visualization-.pdf>
40. Poslovna inteligencija (2016) „Orbico“, [Internet], raspoloživo na: <http://www.inteligencija.com/o-nama/projekti/orbico/>
41. Power BI, [Internet], raspoloživo na: <https://powerbi.microsoft.com/en-us/>
42. Rouse, M. (2014) „Business Intelligence (BI)“, [Internet], raspoloživo na: <http://searchdatamanagement.techtarget.com/definition/business-intelligence>
43. Rouse, M. (2012) „Data visualization“, [Internet], raspoloživo na: <http://searchbusinessanalytics.techtarget.com/definition/data-visualization>
44. SAP Lumira „Self-service data visualization for everyone“, [Internet], raspoloživo na: <https://www.sap.com/products/lumira.html>
45. SAS „Data visualization: What it is and why it matters“, [Internet], raspoloživo na: https://www.sas.com/en_us/insights/big-data/data-visualization.html
46. Smolic H. (2012) „Doznajte što se zapravo krije iza pojma “Business Intelligence/Poslovna inteligencija”“, Poslovni Plus, [Internet], raspoloživo na: <http://www.poslovnipuls.com/2012/10/10/business-intelligence-poslovna-inteligencija/>
47. Stedman, C. (2013) „Dashboard tools lighten burdens on business users, but not BI teams“, [Internet], raspoloživo na: <http://searchbusinessanalytics.techtarget.com/feature/Dashboard-tools-lighten-burdens-on-business-users-but-not-BI-teams>
48. Super Decisions „About SuperDecisions“, [Internet], raspoloživo na: <https://www.superdecisions.com/about/>
49. Tableau, [Internet], raspoloživo na: <https://www.tableau.com/products/desktop>
50. Tableau „Barclays innovates with customer insight from Teradata & Tableau“, [Internet], raspoloživo na: <https://www.tableau.com/solutions/customer/data-access-leads-innovation-across-barclays>

51. Tableau „Seattle Children’s accesses fast, reliable supply chain data“, [Internet], raspoloživo na: <https://www.tableau.com/solutions/customer/seattle-childrens-accesses-fast-reliable-supply-chain-data>
52. Tableau „Swedish Medical shares quality metrics to improve care & save millions“, [Internet], raspoloživo na: <https://www.tableau.com/solutions/customer/swedish-medical-center-sharing-improves-caring-and-offers-millions-dollars-worth>
53. Tableau „Wells Fargo wrangles data from over 70 million customers to redesign customer banking portal“, [Internet], raspoloživo na: <https://www.tableau.com/solutions/customer/storytelling-big-data-wells-fargo>
54. TechTarget „Dashboard development and data visualization tools for effective BI“, [Internet], raspoloživo na: <http://searchbusinessanalytics.techtarget.com/essentialguide/Dashboard-development-and-data-visualization-tools-for-effective-BI>

Popis slika

Slika 1. Važnost trendova poslovne inteligencije u 2017. godini	14
Slika 2. Usporedba važnosti trendova u 2016. i 2017. godini.....	15
Slika 3. Vizualizacija podataka	23
Slika 4. Gartner magic quadrant for business intelligence 2017.....	40
Slika 5. Microsoft Power BI izvještaj na različitim uređajima	42
Slika 6. Microsoft Power BI dashboard	42
Slika 7. Spajanje Tableau-a na razne izvore podataka	44
Slika 8. Izgled Tableau Dashboard-a	45
Slika 9. QlikSense dashboard.....	47
Slika 10. Hijerarhija AHP modela u alatu Super Decisions.....	54
Slika 11. Usporedba kriterija u alatu Super Decisions	55
Slika 12. Kategorije kreirane za svaki od kriterija za odabir alata.....	56
Slika 13. Tablica Super Decision Ratings	56
Slika 14. Rezultati AHP metode	57
Slika 15. Tablica Super Decision Ratings za usporedbu svjetskih alata i BusinessQ.....	71
Slika 16. Usporedba Hrvatskog alata BusinessQ sa svjetskim alatima.....	72

Popis tablica

Tablica 1. Saaty-eva ljestvica.....	52
-------------------------------------	----

Popis grafikona

Grafikon 1. Prikaz rezultata AHP metode u alatu Excel.....	57
Grafikon 2. Usporedba alata s obzirom na kriterij Self service analiza	59
Grafikon 3. Usporedba alata s obzirom na kriterij izvori podataka	61
Grafikon 4. Usporedba alata s obzirom na kriterij obrade velike količine podataka	62
Grafikon 5. Usporedba alata u odnosu na kriterij dijeljenje informacija	63
Grafikon 6. Usporedba alata s obzirom na kriterij jednostavnost upotrebe	65
Grafikon 7. Usporedba alata u odnosu na kriterij praćenje procesa i alerti	67
Grafikon 8. Usporedba alata u odnosu na kriterij vizualizacije podataka.....	68
Grafikon 9. Usporedba alata u odnosu na kriterij personalizacija	69
Grafikon 10. Usporedba alata za vizualizaciju podataka u Excelu	73